PATENT
Attorney Docket No.: 16869K-086100US
Client Ref. No.: 632/SM

IN THE UNITED STATES PATENT AND TRADEMARK OFFICE

In re application of:

YUTAKA TAKATA et al.

Application No.: 10/632,750

Filed: August 1, 2003

For: DISK CONTROLLER AND CONTROLLING METHOD OF THE SAME

Customer No.: 20350

Examiner: Unassigned

Technology Center/Art Unit: Unassigned

Confirmation No.: 4662

PETITION TO MAKE SPECIAL FOR NEW APPLICATION UNDER M.P.E.P. § 708.02, VIII & 37 C.F.R. § 1.102(d)

Commissioner for Patents
P.O. Box 1450
Alexandria, VA 22313-1450

Sir:

This is a petition to make special the above-identified application under MPEP § 708.02, VIII & 37 C.F.R. § 1.102(d). The application has not received any examination by an Examiner.

(a) The Commissioner is authorized to charge the petition fee of $130 under 37 C.F.R. § 1.17(i) and any other fees associated with this paper to Deposit Account 20-1430.

(b) All the claims are believed to be directed to a single invention. If the Office determines that all the claims presented are not obviously directed to a single invention, then Applicants will make an election without traverse as a prerequisite to the grant of special status.

(c) Pre-examination searches were made of U.S. issued patents, including a classification search, a computer database search, and a keyword search. The searches were performed on or around July 12, 2004. The classification search covered Class 710 (subclass 6), Class 711 (subclasses 162 and 170), and Class 714 (subclass 2), and was conducted by a professional search firm, Kramer & Amado, P.C. The computer database search was conducted on the USPTO systems EAST and WEST. The keyword search was conducted in Classes 709 (subclasses 203, 218, 223, and 226), 711 (subclass 112), and 714 (subclasses 5 and 6). The inventors further provided references considered most closely related to the subject matter of the present application (see references #6-11 below), which were cited in the Information Disclosure Statement filed with the application on August 1, 2003.

(d) The following references, copies of which are attached herewith, are deemed most closely related to the subject matter encompassed by the claims:

(1) U.S. Patent No. 5,768,623;
(2) U.S. Patent No. 6,449,607 B1;
(3) U.S. Patent Publication No. 2002/0178336 A1;
(4) U.S. Patent Publication No. 2003/0105767 A1;
(5) U.S. Patent Publication No. 2004/0098543 A1;
(6) Japanese Patent Publication No. 2000-047952;
(7) Japanese Patent Publication No. 06-332782;
(8) Japanese Patent Publication No. 2002-163140;
(9) Japanese Patent Publication No. 2001-051890;
(10) Japanese Patent Publication No. 2000-207370; and
(11) Japanese Patent Publication No. 08-335144.

(e) Set forth below is a detailed discussion of references which points out with particularity how the claimed subject matter is distinguishable over the references.

A. Claimed Embodiments of the Present Invention

The claimed embodiments relate to a disk controller and a method of controlling the same to provide high performance.

Independent claim 1 recites a disc controller comprising a network controlling unit configured to receive a data input/output request sent from an external device through a network; and a disc controlling unit formed in the same circuit board in which the network controlling unit is formed, the disc controlling unit coupled to the network controlling unit by an internal bus provided in the circuit board. The disc controlling unit is configured to receive a command sent from the network controlling unit through the internal bus and executes a data input/output for a disc drive in response to the command. The network controlling unit is configured to send the command, for which a plurality of addresses are set, to the disc controlling unit. The disc controlling unit is configured to receive the command and executes data input/output corresponding to each of the addresses set in the command for the disc drive.

Independent claim 13 recites a disc controller comprising a network controlling unit configured to receive a data input/output request sent through a network; and a disc controlling unit formed in the same circuit board in which the network controlling unit is formed, the disc controlling unit being coupled to the network controlling unit by an internal bus provided in the circuit board, receiving a command sent from the network controlling unit through the internal bus, and inputting/outputting data to/from a disc drive in response to the command. The plurality of circuit boards connected so as to be capable of communicating with each other are provided. An occurrence of faults of one of the circuit boards is detected by one of the other circuit boards by exchanging a heartbeat message among the circuit boards. When the occurrence of the faults of one circuit board is detected by one of the other circuit boards, the circuit board different from the circuit board causing the faults substitutes for a processing of the circuit board causing the faults.

Independent claim 14 recites a controlling method of a disc controller having a network controlling unit configured to receive a data input/output request sent from an external device through a network; and a disc controlling unit formed in the same circuit board in which the network controlling unit is formed. The disc controlling unit is connected to the network controlling unit by an internal bus provided in the circuit board, receives a command sent from the network controlling unit through the internal bus, and inputs/outputs data to/from a disc drive in response to the command. The method comprises, by means of the network controlling unit sending one command, for which a plurality of addresses are set, to the disc controlling unit; and by means of the disc controlling unit receiving the command and executing data input/output corresponding to each of the addresses set in this command for the disc drive.

One of the benefits that may be derived is the high speed and high reliability with which the processing of the disk controller can be performed.

B. Discussion of the References

None of the following references disclose or suggest a disc controlling unit formed in the same circuit board in which the network controlling unit is formed, the disc controlling unit coupled to the network controlling unit by an internal bus provided in the circuit board.

1. U.S. Patent No. 5,768,623

This reference discloses an architecture which uses host adapter cards that can reside in the host and can control numerous arrays. A plurality of adapter cards is used. Each adapter has controller functions for a designated storage array. There is a host application interface between an application program running in the host computer 20 and the adapter 22. When a data request is made by an application program to a first adapter A through a host application interface for data that is stored in a storage array not primarily controlled by the first adapter, the data request is communicated through the adapter communication interface

23 to the adapter B primarily controlling the storage array in which the requested data is stored. See column 2, line 45 to column 3, line 30; column 3, line 57 to column 4, line 27.

2. U.S. Patent No. 6,449,607 B1

This reference discloses a disk storage device 100 having a modifiable data management function. The disk storage device is connected to an interface 105 which connects to a network 110. A processor 103 carries out an object management program 350 for converting a control command containing physical address information of the disk storage medium 101 and feeds the converted control command to the disk controller 102. In response to an object management modification request given by the user through the network 110 and the network interface 105, the processor 103 carries out the object management modification program 320 to modify a function of the object management program 350. See column 2, lines 32-65; column 4, lines 18-39.

3. U.S. Patent Publication No. 2002/0178336 A1

This reference discloses a storage subsystem capable of effecting remote copy of write data among a group of storage subsystems without being affected by an increase in the load of data writing by a specific host computer among a plurality of host computers connected to the storage subsystems. The storage subsystem includes a first storage subsystem 1 connected to a plurality of host computers 3 via a first interface 2 and a second storage subsystem 7 connected to the first storage subsystem 1 via a second interface 6 so as to copy write data written in the first storage subsystem from the host computer onto the second storage subsystem from the first storage subsystem, thereby protecting the write data in the first and the second storage subsystems in a multiplex manner. See Figure 1 and [0016]-[0026].

4. U.S. Patent Publication No. 2003/0105767 A1

This reference discloses a method for interfacing of SAN (Storage Area Networks) and NAS (Network Attached Storage), and prevents data miss even when a trouble occurs, and makes it possible that an arbitrary number of NAS interfaces access the same file system with high performance. The storage subsystem 100 includes a plurality of interfaces (110, 120, 130, 140, and 150) for the connection to the external network (600 and 700), a plurality of disks 171 to which the plurality of interfaces are accessible, and a shared memory 180 to which the plurality of interfaces are accessible, wherein the plurality of interfaces are loaded with one of the block interfaces for executing an I/O request in disk blocks, and file interfaces are loaded with file servers for executing an I/O request in files. See Figure 1 and [0016]-[0021].

5. U.S. Patent Publication No. 2004/0098543 A1

This reference relates to a storage subsystem which is capable of performing exclusive control of input/output processing requests without need for imparting to the host processing system. The storage subsystem is comprised of a control unit 12 incorporating a control memory 124, wherein information concerning the extent (range) of an input/output processing request which is transferred from a given one of plural host processors to the control unit upon issuance of the input/output processing request from the former is stored in the control memory with a view to realizing the exclusive control for a plurality of input/output processing requests issues from a plurality of host processors to one logical device. See [0001], [0006]-[0007] and [0024-0027].

6. Japanese Patent Publication No. 2000-047952

This reference discloses a means of efficiently performing I/O processing while minimizing the use of processor, main storage, and system bus resources of a server computer by directly transferring data between a network card and an I/O device such as a network adapter or disk controller. In the network file server system, in processing a remote

file system request by a network card, data is directly transferred between a disk controller and the network card. The number of times the data transfer uses main memory between the disk controller and network card is decreased so that high speed processing is enabled.

7. Japanese Patent Publication No. 06-332782

This reference discloses a technique to prevent the throughput due to the centralization of access requests in a specified file server from plural clients, in a file server system where plural file servers accessing each file storage devices are arranged side by side via a network. The master file server provides a file control means by using a load information table to measure and control the load status of each file server, and a file attribute table that records and controls the file server in charge of access to every file block, selecting a file server where the load is light at the time of writing a file.

8. Japanese Patent Publication No. 2002-163140

This reference discloses a storage system that has a scalability capable of fully coping with the band expansion of a network at a low cost. The storage system is comprised of a storage device capable of storing file data, a plurality of file servers performing file processes in response to requests on file data to the storage device, and a file server managing the transfer processes of the file requests received from clients via an external network to the file servers. An internal network connects the response processes to the clients for the file requests, the storage device, the file servers, and the file server.

9. Japanese Patent Publication No. 2001-051890

This reference discloses a decentralized file server system. The system is equipped with servers decentralized in the network and a virtual decentralized file system mounted on each of the servers. Modules judge whether or not their servers are optimum servers capable of handling requests according to server information holding parts, holding mapping tables between the virtual decentralized file system, all the local file systems, and the server information on all the servers.

10. Japanese Patent Publication No. 2000-207370

This reference discloses a technique to provide a distributed file management system which can make appropriate load distribution by means of plural server computers for generating, referring to, and updating files. The distributed file management system is comprised of server computers, client computer groups, and a network. The server computer contains a storage device which records partial files, a network interface, a partial file management section which controls the write and read of the partial files, a status management section which holds load information, and a distributed file management section.

11. Japanese Patent Publication No. 08-335144

This reference discloses a technique to improve reliability and performance of an external storage device, and to provide non-stop maintenance by distributing a load to the plural storage controllers of redundant configuration. Plural disk drive controllers of redundant configuration for controlling a disk device are connected to a host device by the same SCSI ID. These controllers monitor the mutual operating states and set the load distribution information by interposing a communication mechanism and a common managing table in a normal state. High performance is provided by distributing the load by simultaneously operating the plural disk drive controllers, but in case of fault or maintenance, non-stop operation and non-stop maintenance are provided by executing a switching operation at the degeneracy, and recovery can be achieved by disconnecting on the side of the fault.

(f) In view of this petition, the Examiner is respectfully requested to issue a first Office Action at an early date.

Respectfully submitted,

Chun-Pok Leung
Reg. No. 41,405

TOWNSEND and TOWNSEND and CREW LLP
Two Embarcadero Center, 8th Floor
San Francisco, California 94111-3834
Tel: 650-326-2400
Fax: 415-576-0300

Attachments
RL:rl
60269491 v1

FEE TRANSMITTAL for FY 2004

Effective 10/01/2003. Patent fees are subject to annual revision.

☐ Applicant claims small entity status. See 37 CFR 1.27

TOTAL AMOUNT OF PAYMENT | ($) 130.00

Complete if Known	
Application Number	10/632,750
Filing Date	August 1, 2003
First Named Inventor	TAKATA, Yutaka
Examiner Name	Unassigned
Art Unit	Unassigned
Attorney Docket No.	16869K-086100US

METHOD OF PAYMENT *(check all that apply)*

☐ Check ☐ Credit Card ☐ Money Order ☐ Other ☐ None

☒ Deposit Account:

Deposit Account Number: 20-1430

Deposit Account Name: Townsend and Townsend and Crew LLP

The Director is authorized to: *(check all that apply)*

☒ Charge fee(s) indicated below ☒ Credit any overpayments

☒ Charge any additional fee(s) or any underpayment of fee(s)

☐ Charge fee(s) indicated below, **except for the filing fee** to the above-identified deposit account.

FEE CALCULATION

1. BASIC FILING FEE

Large Entity Fee Code	Large Entity Fee ($)	Small Entity Fee Code	Small Entity Fee ($)	Fee Description	Fee Paid
1001	770	2001	385	Utility filing fee	
1002	340	2002	170	Design filing fee	
1003	530	2003	265	Plant filing fee	
1004	770	2004	385	Reissue filing fee	
1005	160	2005	80	Provisional filing fee	

SUBTOTAL (1) ($)0.00

2. EXTRA CLAIM FEES FOR UTILITY AND REISSUE

		Extra Claims	Fee from below	Fee Paid
Total Claims	-** =		x =	
Independent Claims	-** =		x =	
Multiple Dependent			x =	

Large Entity Fee Code	Large Entity Fee ($)	Small Entity Fee Code	Small Entity Fee ($)	Fee Description
1202	18	2202	9	Claims in excess of 20
1201	86	2201	43	Independent claims in excess of 3
1203	290	2203	145	Multiple dependent claim, if not paid
1204	86	2204	43	** Reissue independent claims over original patent
1205	18	2205	9	** Reissue claims in excess of 20 and over original patent

SUBTOTAL (2) ($)0.00

**or number previously paid, if greater; For Reissues, see above*

FEE CALCULATION (continued)

3. ADDITIONAL FEES

Large Entity Fee Code	Large Entity Fee ($)	Small Entity Fee Code	Small Entity Fee ($)	Fee Description	Fee Paid
1051	130	2051	65	Surcharge - late filing fee or oath	
1052	50	2052	25	Surcharge - late provisional filing fee or cover sheet.	
1053	130	1053	130	Non-English specification	
1812	2,520	1812	2,520	For filing a request for reexamination	
1804	920*	1804	920*	Requesting publication of SIR prior to Examiner action	
1805	1,840*	1805	1,840*	Requesting publication of SIR after Examiner action	
1251	110	2251	55	Extension for reply within first month	
1252	420	2252	210	Extension for reply within second month	
1253	950	2253	475	Extension for reply within third month	
1254	1,480	2254	740	Extension for reply within fourth month	
1255	2,010	2255	1,005	Extension for reply within fifth month	
1401	330	2401	165	Notice of Appeal	
1402	330	2402	165	Filing a brief in support of an appeal	
1403	290	2403	145	Request for oral hearing	
1451	1,510	1451	1,510	Petition to institute a public use proceeding	
1452	110	2452	55	Petition to revive – unavoidable	
1453	1,330	2453	665	Petition to revive – unintentional	
1501	1,330	2501	665	Utility issue fee (or reissue)	
1502	480	2502	240	Design issue fee	
1503	640	2503	320	Plant issue fee	
1460	130	1460	130	Petitions to the Commissioner	130
1807	50	1807	50	Petitions related to provisional applications	
1806	180	1806	180	Submission of Information Disclosure Stmt	
8021	40	8021	40	Recording each patent assignment per property (times number of properties)	
1809	770	2809	385	Filing a submission after final rejection (37 CFR § 1.129(a))	
1810	770	2810	385	For each additional invention to be examined (37 CFR § 1.129(b))	
1801	770	2801	385	Request for Continued Examination (RCE)	
1802	900	1802	900	Request for expedited examination of a design application	
				Other fee (specify) ----------	

*Reduced by Basic Filing Fee Paid **SUBTOTAL (3)** ($)130.00

SUBMITTED BY *Complete (if applicable)*

Name (Print/Type)	Chun-Pok Leung	Registration No. (Attorney/Agent)	41,405	Telephone	650-326-2400
Signature				Date	August 30, 2004

WARNING: Information on this form may become public. Credit card information should not be included on this form. Provide credit card information and authorization on PTO-2038.

60295530 v1

PATENT ABSTRACTS OF JAPAN

(11)Publication number : 2000-047952
(43)Date of publication of application : 18.02.2000

(51)Int.Cl. G06F 13/00
G06F 12/00

(21)Application number : 10-211357
(22)Date of filing : 27.07.1998

(71)Applicant : TOSHIBA CORP
(72)Inventor : TOMOTA MASANORI

(54) NETWORK FILE SERVER SYSTEM AND FILE MANAGING METHOD IN THE SYSTEM

(57)Abstract:
PROBLEM TO BE SOLVED: To provide a means for efficiently performing I/O processing while minimizing the use of processor, main storage and system bus resource of a server computer by directly transferring data between a network card and an I/O device such as network adapter or disk controller.
SOLUTION: In this network file server system, in the case of processing a remote file system request through a remote file processing means 136 by a network card 130 while using a file on a disk through a local file system 160 for an application or operating system(OS) to be operated on a server computer 100, data are directly transferred between a disk controller 140 and the network card 130. Thus, the number of times of data transfer using a main memory 120 between the disk controller 140 and network card 130 is decreased so that high-speed processing is enabled.

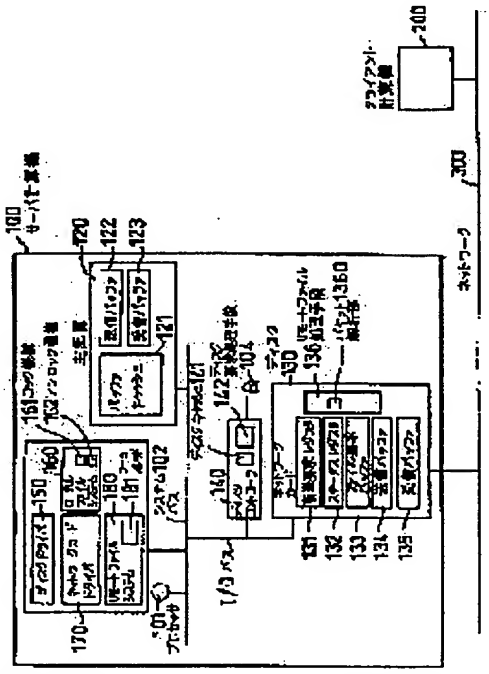

LEGAL STATUS

[Date of request for examination]

[Date of sending the examiner's decision of rejection]

[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]

[Date of final disposal for application]

[Patent number]

[Date of registration]

[Number of appeal against examiner's decision of rejection]

[Date of requesting appeal against examiner's decision of rejection]

[Date of extinction of right]

* NOTICES *

CLAIMS

[Claim(s)]
[Claim 1] Manage the above-mentioned storage with the means of communications characterized by providing the following, and the file on this storage is managed. A local file control means with the function to return the information which pinpoints the position of the disk which stores the above-mentioned file to the demand which asks the position on the above-mentioned storage of the above-mentioned file, It has a remote file control means to write the file on the above-mentioned storage based on the content of the remote file system demand from the above-mentioned client computer. The above-mentioned remote file-processing section analyzes the packet which the above-mentioned receive buffer received. The remote file system demand which is an operation demand to the file which the above-mentioned local file control means which the above-mentioned client computer contained in this packet transmitted manages is taken out. When this remote file system demand needs the data transfer from the above-mentioned storage which the above-mentioned local file control means manages, The demand which asks in which position of the above-mentioned storage the file exists is given to the above-mentioned local file control means. A transmitting packet will be created, if it demands to transmit to the above-mentioned storage control means at the above-mentioned transmission buffer based on the positional information which was able to obtain the data of the file concerned and this data is stored in the above-mentioned transmission buffer. The above-mentioned client computer is answered in a remote file system demand. When the above-mentioned remote file system demand needs the data transfer to the above-mentioned storage, The demand which asks in which position of the above-mentioned storage the file concerned exists is given to the above-mentioned local file control means. The data stored in the above-mentioned receive buffer are directly transmitted to the above-mentioned storage control means. The data which the above-mentioned storage control means store in the above-mentioned receive buffer based on the position obtained previously are written in the above-mentioned storage. When the reply to a remote file system demand is performed to the above-mentioned client computer and the above-mentioned remote file system demand does not need the data transfer from the above-mentioned storage The network file server system characterized by passing the demand to the above-mentioned remote file control means. The server computer which offers files, such as various applications. Two or more client computers which access the file which this server computer offers. It is the storage with which it is the network file server system which consists of the network which connects the above-mentioned server computer and the above-mentioned client computer, and the above-mentioned server computer stores information, such as a file. The transmission buffer section which stores the packet which considers protocol processing of the packet transmitted and received to the above-mentioned client computer as the storage control means which control this storage, and transmits to the above-mentioned client computer, the receive buffer section which stores the packet which received from the above-mentioned client computer, and the remote file-processing section which performs processing based on the remote file system demand from the above-mentioned client computer.
[Claim 2] The network file server system which consists of the network which connects the server computer which is characterized by providing the following, and which offers files, such as various applications, two or more client computers which access the file which this server computer offers, and the above-mentioned server computer and the above-mentioned client computer. The above-mentioned server computer is storage which stores information, such as a file. Storage control means which control this storage. Means of communications which prepared the transmission buffer section which stores the packet which carries out protocol processing of the packet transmitted and received to the above-mentioned client computer, and transmits to the above-mentioned client computer, the receive buffer section which stores the packet which received from the above-mentioned client computer, and the remote file-processing section which performs processing based on the remote file system demand from the above-mentioned client computer. Store the data of the above-mentioned file in the puffer cache section on the primary storage of the above-mentioned server computer, and the operation to the above-mentioned file When it carries out on the above-mentioned buffer cache section and the data of the above-mentioned file are stored on the buffer cache section The function to return the address of the data of the file concerned on the above-mentioned buffer cache to this file demand, The function to return the information which pinpoints the position of the disk which stores the above-mentioned file to the demand which manages the above-mentioned storage, manages the file on this storage, and asks the position on the above-mentioned storage of the above-mentioned file.
[Claim 3] The network file server system which consists of the network which connects the server computer which is characterized by providing the following, and which offers files, such as various applications, two or more client computers which access the file which this server computer offers, and the above-mentioned server computer and the above-mentioned client computer. The above-mentioned server computer is storage which stores information, such as a file. Storage control means which control this storage. Means of communications which prepared the transmission buffer section which stores the packet which carries out protocol processing of the packet transmitted and received to the above-mentioned client computer, and transmits to the above-mentioned client computer, the receive buffer section which stores the packet which received from the above-mentioned client computer, and the remote file-processing section which performs processing based on the remote file system demand from the above-mentioned client computer. Store the data of the above-mentioned file in the puffer cache section on the primary storage of the above-mentioned server computer, and the operation to the above-mentioned file When it carries out on the above-mentioned buffer cache section and the data of the above-mentioned file are stored on the buffer cache section The function to return the address of the data of the file concerned on the above-mentioned buffer cache to this file demand, The function to secure the above-mentioned buffer cache section which stores the file concerned based on the above-mentioned file demand, and to return this address when the data of the above-mentioned file are not stored on the buffer cache section, The function to return the information which pinpoints the position of the disk which stores the above-mentioned file to the demand which manages the above-mentioned storage, manages the file on this storage, and asks the position on the above-mentioned storage of the above-mentioned file.
[Claim 4] The network file server system which consists of the network which connects the server computer which is characterized by providing the following, and which offers files, such as various applications, two or more client computers which access the file which this server computer offers, and the above-mentioned server computer and the above-mentioned client computer. The above-mentioned server computer is storage which stores information, such as a file. Storage control means which control this storage. Means of communications which carried out protocol processing of the packet transmitted and received to the above-mentioned client computer, prepared the transmission buffer section which stores the packet which transmits to the above-mentioned client computer, and the receive buffer section which stores the packet which received from the above-mentioned client computer, and prepared the remote file-processing section which processes based on the remote file system demand from the above-mentioned client computer. The function of notifying the positional information on the function of returning the information which pinpoints the position of the disk which stores the above-

mentioned file to the demand which manages the above-mentioned storage, manages the file on this storage, and asks the position on the above-mentioned storage of the above-mentioned file, and the storage store this file in case the writing to the above-mentioned file, deletion, creation, etc. operate, and the file positional information it is the information specify this file to the above-mentioned means of communications.

[Claim 5] Manage the above-mentioned storage with the means of communications characterized by providing the following, and the file on this storage is managed. A local file control means with the function to return the information which pinpoints the position of the disk which stores the above-mentioned file to the demand which asks the position on the above-mentioned storage of the above-mentioned file, It has a remote file control means to write the file on the above-mentioned storage based on the content of the remote file system demand from the above-mentioned client computer. The above-mentioned remote file-processing section analyzes the packet which the above-mentioned receive buffer received. The remote file system demand which is an operation demand to the file which the above-mentioned local file control means which the above-mentioned client computer contained in this packet transmitted manages is taken out. When this remote file system demand needs the data transfer from the above-mentioned storage which the above-mentioned local file control means manages, The demand which asks in which position of the above-mentioned storage the file exists is given to the above-mentioned local file control means. A transmitting packet will be created, if it demands to transmit to the above-mentioned storage control means at the above-mentioned transmission buffer based on the positional information which was able to obtain the data of the file concerned and this data is stored in the above-mentioned transmission buffer. The above-mentioned client computer is answered in a remote file system demand. When the above-mentioned remote file system demand needs the data transfer to the above-mentioned storage, The demand which asks in which position of the above-mentioned storage the file concerned exists is given to the above-mentioned local file control means. The data stored in the above-mentioned receive buffer are directly transmitted to the above-mentioned storage control means. The data which the above-mentioned storage control means store in the above-mentioned receive buffer based on the position obtained previously are written in the above-mentioned storage. When the reply to a remote file system demand is performed to the above-mentioned client computer and the above-mentioned remote file system demand does not need the data transfer from the above-mentioned storage The file management method in the network file server system characterized by passing the demand to the above-mentioned remote file control means. The server computer which offers files, such as various applications. Two or more client computers which access the file which this server computer offers. It is the storage with which it is the file management method in the network file server system which consists of the network which connects the above-mentioned server computer and the above-mentioned client computer, and the above-mentioned server computer stores information, such as a file. The transmission buffer section which stores the packet which considers protocol processing of the packet transmitted and received to the above-mentioned client computer as the storage control means which control this storage, and transmits to the above-mentioned client computer, the receive buffer section which stores the packet which received from the above-mentioned client computer, and the remote file-processing section which performs processing based on the remote file system demand from the above-mentioned client computer.

[Claim 6] The file management method of the network file server system which consists of a network which connects the server computer which is characterized by providing the following, and which offers files, such as various applications, two or more client computers which access the file which this server computer offers, and the above-mentioned server computer and the above-mentioned client computer. The above-mentioned server computer is storage which stores information, such as a file. Storage control means which control this storage. Means of communications which prepared the transmission buffer section which stores the packet which carries out protocol processing of the packet transmitted and received to the above-mentioned client computer, and transmits to the above-mentioned client computer, the receive buffer section which stores the packet which received from the above-mentioned client computer, and

the remote file-processing section which performs processing based on the remote file system demand from the above-mentioned client computer. Store the data of the above-mentioned file in the puffer cache section on the primary storage of the above-mentioned server computer, and the operation to the above-mentioned file When it carries out on the above-mentioned buffer cache section and the data of the above-mentioned file are stored on the buffer cache section The function to return the address of the data of the file concerned on the above-mentioned buffer cache to this file demand, The function to return the information which pinpoints the position of the disk which stores the above-mentioned file to the demand which manages the above-mentioned storage, manages the file on this storage, and asks the position on the above-mentioned storage of the above-mentioned file.

[Claim 7] The file management method of the network file server system which consists of a network which connects the server computer which is characterized by providing the following, and which offers files, such as various applications, two or more client computers which access the file which this server computer offers, and the above-mentioned server computer and the above-mentioned client computer. The above-mentioned server computer is storage which stores information, such as a file. Storage control means which control this storage. Means of communications which prepared the transmission buffer section which stores the packet which carries out protocol processing of the packet transmitted and received to the above-mentioned client computer, and transmits to the above-mentioned client computer, the receive buffer section which stores the packet which received from the above-mentioned client computer, and the remote file-processing section which performs processing based on the remote file system demand from the above-mentioned client computer. Store the data of the above-mentioned file in the puffer cache section on the primary storage of the above-mentioned server computer, and the operation to the above-mentioned file When it carries out on the above-mentioned buffer cache section and the data of the above-mentioned file are stored on the buffer cache section The function to return the address of the data of the file concerned on the above-mentioned buffer cache to this file demand, The function to secure the above-mentioned buffer cache section which stores the file concerned based on the above-mentioned file demand, and to return this address when the data of the above-mentioned file are not stored on the buffer cache section, The function to return the information which pinpoints the position of the disk which stores the above-mentioned file to the demand which manages the above-mentioned storage, manages the file on this storage, and asks the position on the above-mentioned storage of the above-mentioned file.

[Claim 8] The file management method of the network file server system which consists of a network which connects the server computer which is characterized by providing the following, and which offers files, such as various applications, two or more client computers which access the file which this server computer offers, and the above-mentioned server computer and the above-mentioned client computer. The above-mentioned server computer is storage which stores information, such as a file. Storage control means which control this storage. Means of communications which carried out protocol processing of the packet transmitted and received to the above-mentioned client computer, prepared the transmission buffer section which stores the packet which transmits to the above-mentioned client computer, and the receive buffer section which stores the packet which received from the above-mentioned client computer, and prepared the remote file-processing section which processes based on the remote file system demand from the above-mentioned client computer. The function of notifying the positional information on the function of returning the information which pinpoints the position of the disk which stores the above-mentioned file to the demand which manages the above-mentioned storage, manages the file on this storage, and asks the position on the above-mentioned storage of the above-mentioned file, and the storage store this file in case the writing to the above-mentioned file, deletion, creation, etc. operate, and the file positional information it is the information specify this file to the above-mentioned means of communications.

[Translation done.]

* NOTICES *

1.This document has been translated by computer. So the translation may not reflect the original precisely.
2.**** shows the word which can not be translated.
3.In the drawings, any words are not translated.

DETAILED DESCRIPTION

[Detailed Description of the Invention]
[0001]
[The technical field to which invention belongs] this invention accesses the file on a server computer through networks, such as a public correspondence network and LAN (Local Area Network) of a cable and radio, from two or more client computers, and relates to the file management method in the network file server system which transmits and receives data, and a network file server system.
[0002]
[Description of the Prior Art] As conventionally shown in drawing 8 , in the network file server 10, it was what exchanges information between the client computer 25 and a network file server 10. That is, the packet which stored the file manipulation demand reaches the network card 18 of a network file server 10 (it is hereafter called the server computer 10) via the networks 24, such as LAN, from (1) client computer 25.
[0003] (2) The network driver 20 transmits the packet which reached the network card 18 of the server computer 10 to a primary storage 14 from the receive buffer 19 of the network card 18.
[0004] (3) The protocol stack 21 which analyzes communications protocols, such as TCP/IP, analyzes the content of a packet, takes out the file manipulation demand stored in the packet, and passes the remote file system 22.
[0005] (4) The remote file system 22 passes a file manipulation demand to the local file system 23. The local file system 23 is a file system which manages the disk 17 of the server computer 10.
[0006] (5) The local file system 23 processes a file manipulation demand. The result is returned to the remote file system 22.
[0007] (6) The remote file system 22 creates the packet which stored the result, and transmits a result to the client computer 25 via a protocol stack 21, the network card 18, and a network 24.
[0008] The software which processes the packet which arrived is the network driver 20, a protocol stack 21, the remote file system 22, and the local file system 23. These shall be installed on storage, such as a disk.
[0009] The processor 11 of the server computer 10 performs such software on a primary storage 14. In processing of a file manipulation demand, the data between a disk 17 and the network card 18 are exchanged via a primary storage 14.
[0010] In the old server computer 10, processing of the protocol stack 21 which realizes reliable data transmission and reception took time, and many processor resources were consumed.
[0011] Moreover, in network file service etc., an exchange of data occurs using a disk controller 16 and the network card 18. Both of the devices are connected to I/O bus 13 (it realizes by the PCI bus etc.) of the server computer 10.
[0012] Therefore, after the software (the processor of a server computer performs) which controls the device of the network card 18 and disk controller 16 grade processed by once transmitting data to a primary storage until now, data were further transmitted to each device.
[0013]
[Problem(s) to be Solved by the Invention] If it was in the conventional server computer 10 as

mentioned above, processing of the protocol stack 21 which realizes reliable data transmission and reception took time, and many processor resources were consumed. Moreover, in network file service etc., it was what an exchange of data generates using a disk controller 16 and the network card 18. Both of the devices are connected to I/O bus 13 (it realizes by the PCI bus etc.) of the server computer 10.
[0014] Therefore, after the software (the processor of a server computer performs) which controls the device of the network card 18 and disk controller 16 grade processed by once transmitting data to a primary storage conventionally, data were further transmitted to each device.
[0015] Then, in consideration of the above-mentioned situation, accomplished this invention, and it cancels the above-mentioned fault. The file on a server computer is accessed through networks, such as a public correspondence network and LAN of a cable and radio, from two or more client computers. By being in the network file server system which transmits and receives data, and exchanging data directly among I/O devices, such as a network adapter and a disk controller Use of the processor of a server computer, a primary storage, and system bus resources is suppressed to the minimum, and it aims at offering the file management method in the network file server system which can perform I/O processing efficiently, and a network file server system.
[0016]
[Means for Solving the Problem] this invention in order to attain the above-mentioned purpose the network file server system of this invention The server computer which offers files, such as various applications, and two or more client computers which access the file which this server computer offers, It is the network file server system which consists of a network which connects the above-mentioned server computer and the above-mentioned client computer. the above-mentioned server computer The storage which stores information, such as a file, and the storage control means which control this storage, Protocol processing of the packet transmitted and received to the above-mentioned client computer is carried out. The packet which transmits to the above-mentioned client computer The means of communications which prepared the transmission buffer section to store, the receive buffer section which stores the packet which received from the above-mentioned client computer, and the remote file-processing section which performs processing based on the remote file system demand from the above-mentioned client computer, A local file control means with the function to return the information which pinpoints the position of the disk which stores the above-mentioned file to the demand which manages the above-mentioned storage, manages the file on this storage, and asks the position on the above-mentioned storage of the above-mentioned file, It has a remote file control means to write the file on the above-mentioned storage based on the content of the remote file system demand from the above-mentioned client computer. The above-mentioned remote file-processing section analyzes the packet which the above-mentioned receive buffer received. The remote file system demand which is an operation demand to the file which the above-mentioned local file control means which the above-mentioned client computer contained in this packet transmitted manages is taken out. When this remote file system demand needs the data transfer from the above-mentioned storage which the above-mentioned local file control means manages, The demand which asks in which position of the above-mentioned storage the file exists is given to the above-mentioned local file control means. A transmitting packet will be created, if it demands to transmit to the above-mentioned storage control means at the above-mentioned transmission buffer based on the positional information which was able to obtain the data of the file concerned and this data is stored in the above-mentioned transmission buffer. The above-mentioned client computer is answered in a remote file system demand. When the above-mentioned remote file system demand needs the data transfer to the above-mentioned storage, The demand which asks in which position of the above-mentioned storage the file concerned exists is given to the above-mentioned local file control means. It demands to transmit to the above-mentioned storage control means at the above-mentioned transmission buffer based on the positional information which was able to obtain the data of a file. If this data is stored in the above-mentioned transmission buffer, will create a transmitting packet and the above-mentioned

client computer will be answered in a remote file system demand. When the above-mentioned remote file system demand needs the data transfer to the above-mentioned storage, The demand which asks in which position of the above-mentioned storage the file concerned exists is given to the above-mentioned local file control means. The data stored in the above-mentioned receive buffer are directly transmitted to the above-mentioned storage control means. The data which the above-mentioned storage control means store in the above-mentioned receive buffer based on the position obtained previously are written in the above-mentioned storage. When the reply to a remote file system demand is performed to the above-mentioned client computer and the above-mentioned remote file system demand does not need the data transfer from the above-mentioned storage, it is characterized by constituting so that the demand may be passed to the above-mentioned remote file control means.

[0017] In case a network card processes a remote file system demand, the application and the operating system (OS) which operate on a server computer using the file on a disk through a local file system according to such composition, transmitting immediate data between a disk controller and a network card can perform high-speed processing by reducing the number of times of the data transfer using the primary storage between a disk controller and a network card.

[0018] Furthermore, only a Network File System demand is sent to the remote file system (the processor of a server computer performs) proposed by this invention among the packets which the network card interpreted. At this time, the number of times of data transfer can be reduced from before by sending only a demand to the primary storage of a server computer, and carrying out the direct DMA transfer of the data of a file etc. between a network card and a disk controller.

[0019] If the above-mentioned local file control means is equipped with the function which notifies the positional information on the storage which stores a file with the demand, and the file positional information which is information which specifies this file to the above-mentioned means of communications in addition to this composition, the disk positional information of a file can be obtained still at high speed.

[0020] Moreover, the application and OS which operate on a server computer using the file on a disk through a local file system in addition to this composition In case a network card processes a remote file system demand, the data of the buffer cache on the primary storage which a local file system manages by transmitting to a network card directly Can perform high-speed processing and further an exchange of data with the disk generated in the remote file system demand by storing in a buffer cache Next, the data on a buffer cache can be used to the demand (the application on a server computer lets a local file system pass, or a client computer is as a remote file system demand) to the same file.

[0021]

[Embodiments of the Invention] Hereafter, the gestalt of 1 operation of this invention is explained with reference to a drawing.

[0022] Drawing 1 is the block diagram having shown the network file server structure of a system concerning this operation gestalt. Composition required for explanation of this operation gestalt is shown, and other composition is omitted.

[0023] The networks 300, such as a public correspondence network and LAN of a cable and radio, connect with the server computer 100, and the client computer 200 accesses the file on the server computer 100. This file is a file corresponding to the various applications installed on the server computer, or other applications.

[0024] A processor 101 controls each part of the server computer 100.

[0025] A system bus 102 connects and carries out various data transfer of primary-storage 120 grade and the processor 101.

[0026] I/O bus 103 connects I/O equipment and system buses 102, such as input meanses, such as the network card 130, a disk controller 140, a keyboard that is not illustrated, and a mouse, and a display, and transmits various data.

[0027] A primary storage 120 is a primary storage of the server computer 100, and is equipped with the buffer cache 121, a transmission buffer 122, and a receive buffer 123.

[0028] The remote file system 180, the local file system 160, the network card driver 170, and a disk driver 150 are software, are saved on the storage of disk 104 grade, and are performed by the processor 101.

[0029] The remote file system 180 processes writing the file on the server computer 100 based on the content of a file system demand by the worker thread 181 etc.

[0030] The local file system 160 manages the disk 104 with which the server computer 100 is equipped, and is equipped with the lock function 161 and the unlocking function 162. About the function of the lock function 161 and the unlocking function 162, it mentions later.

[0031] The network card driver 170 controls the network card 130.

[0032] A disk driver 150 controls a disk 104 by the disk controller 140.

[0033] The server computer 100 is equipped with the network card 130 which performs protocol processing for performing transmission and reception of the client computer 200 and data. As a result of performing protocol processing of the packet transmitted and received between the server computer 100 and the client computer 200, when the packet is not the file system demand whose R/W etc. carries out the file on the server computer 100 from the client computer 200, this network card 130 cooperates with the network card driver 170, and performs the same processing as the usual network card.

[0034] Moreover, the network card 130 processes writing the file on the server computer 100 based on the content of a file system demand etc. in harmony with the network card driver 170 which operates on the server computer 100, and the worker thread 181 on the remote file system 180, when the above-mentioned packet which carries out transmission and reception is a file system demand.

[0035] The above-mentioned network card 130 consists of the following.

[0036] Perform protocol processing of a receive packet, and when the receive packet is a file system demand The file demand buffer 133 and receive packet which store the content of the packet which a remote file-processing means 136 to perform the processing, and the remote file-processing means 136 analyzed in the usual packet Or it consists of the status register 132 which stores the information which shows a file system demand etc., the receive buffer 135 which once stores the packet transmitted from the alien machine, a transmission buffer 134 which accumulates the packet which should transmit, and a transfer-request register 131.

[0037] Data transfer of the transfer-request register 131 is carried out to the address of the storing origin of data from there, and the information on the address of the point which stores the data is stored. For example, when transmit data is on the buffer cache 121, the address on the buffer cache 121 of the data and the address on the transmission buffer 134 which is the data transfer point are stored. When received data are on a receive buffer 135, the address on the receive buffer 135 of the data and the address on the buffer cache 121 which is the data transfer point are stored.

[0038] The value which shows the status stored in a status register 132 is carried out as follows here. 1 shows read/write demand reception of a file system, 2 usually shows packet reception, and 3 shows DMA transfer completion, and 4 shows the usual packet transmitting processing.

[0039] The file demand buffer 133 consists of the remote file system demand 1330 (a lead, a light, in addition to this), the target file name 1331, its offset 1332, a data length 1333, and a data address 1334, as shown in drawing 2 .

[0040] The local file system 160 manages the disk with which the server computer 100 is equipped. That is, a file is stored on a disk 104 and functions, such as creation of a file, a lead, a light, and deletion, are offered. The buffer cache 121 is created on a primary storage 120, and the cache of the data of a file is carried out. Furthermore, it has the following functions.

[0041] 1. Judge whether the content to which the file corresponds is in the buffer cache 121 by considering a file name, offset, and a data length as an input. In being in the buffer cache 121, it returns the address of the buffer.

[0042] 2. Lock function 161 to forbid file manipulation demand to corresponding buffer by considering the address of buffer as input, and unlocking function 162 to cancel it.

[0043] 3. Return the position (disk block) of the disk which stores the corresponding data by considering a file name, offset, and a data length as an input.

[0044] A disk controller 140 is equipped with the disk cache 141 which once stores the disk demand processing means 142 and the data which read from the disk 104 or are written in a disk 104.
[0045] The network card driver 170 which the server computer 100 performs is equipped with the following functions.
[0046] 1. Process interruption from the network card 130.
[0047] 2. Transmit and receive the usual packet.
[0048] 3. Secure a transmission buffer 122 and a receive buffer 123 on a primary storage 120.
[0049] The worker thread 181 which the processor 101 of the server computer 100 performs receives a remote file system demand, and takes charge of the processing.
[0050] Processing begins from the place where, as for a remote file system demand, the client computer 200 transmits a demand to the server computer 100. Hereafter, the client computer 200 advances a remote file system demand, and the flow chart of drawing 3 explains how the server computer 100 processes the demand.
[0051] First, if the remote file-processing means 136 of the network card 130 has reception of a packet from the client computer 200, it will perform the following operation. Here, the example which uses Ethernet for communication and uses TCP/IP for the protocol is explained.
[0052] When the packet addressed to network card 130 is sent on a network 300, the packet is accumulated to a receive buffer 135 (Step A1).
[0053] The packet accumulated to the receive buffer 135 is analyzed, and the packet analysis section 1360 which performs protocol processing of TCP/IP analyzes the data division of a packet, and judges whether it is the protocol which can be processed (Step A2).
[0054] In the case of the protocol which cannot be processed (No of Step A2), Step A8 is processed.
[0055] In the case of the protocol which can be processed (Yes of Step A2), the packet analysis section 1360 performs protocol processing (Step A3).
[0056] Next, it judges whether it is the demand to the remote file system 180 (Step A4). Here, since it is transmitted to the port of TCP/IP defined beforehand, the demand to the remote file system 180 can be easily judged, if the port number of a packet is supervised.
[0057] In the demand to the remote file system 180, (Yes of Step A4) and a status register 132 are set to 1 (read/write demand reception of a file system) (step A5).
[0058] A file system demand is taken out from a packet and it stores in the file demand buffer 133. The demand consists of file manipulation, a file name, offset, a data length, etc. Furthermore, when a demand is a lead, the transmission buffer 134 on the network card 130 is secured, and the address is stored in the data address of the file demand buffer 133. In a light demand, the address of the receive buffer 135 on the network card 130 which stored the data which should be written in is stored in the data address of the file demand buffer 133 (Step A6).
[0059] Then, interruption is applied to a processor (Step A7).
[0060] When it is not the demand to the remote file system 180, in file system demands other than a lead and light processing, a packet is transmitted to the receive buffer 135 on the primary storage 120 which the network card driver 170 secured beforehand as (No of Step A4), and a usual packet. A status register is set to 2 (usually packet reception) (Step A8), and interruption is applied to a processor (Step A7).
[0061] When it is processing with much data transfer, data are directly exchanged between the network card 130 and a disk controller 140 by the method of proposing by this invention. In explanation of this example, although only the lead and the light demand are treated, in addition if there is a demand with the large amount of data transfer, it will process similarly.
[0062] Next, processing operation of the DMA transfer of the network card 130 is explained with reference to the flow chart of drawing 4 .
[0063] Data are sent to the transmission place address by the DMA transfer from the transmitting agency address set to the transfer-request register 131 (storing) (Step B1).
[0064] A status register 132 is set to 3. 3 shows DMA transfer completion (step B-2).
[0065] Interruption is applied to a processor (Step B3).
[0066] Next, the flow chart of drawing 5 explains processing operation of transmission of the

network card 130.
[0067] By the packet analysis section 1360, a packet judges whether it is the usual packet transmission (Step C1).
[0068] In the usual packet transmission (Yes of Step C1), the usual packet transmission is performed (Step C2). Then, a status register 132 is set to 4 (Step C3 (4 shows the usual packet transmitting processing)), and interruption is applied to a processor (Step C4).
[0069] When it is not the usual packet transmission (No of Step C1), the data 134 of a transmission buffer and the answer to the cline ANTO computer 200 from a file demand are created (Step C5). Protocol processing is performed by the packet analysis section 1360 about this created packet (Step C6). A packet is transmitted to a network (Step C7).
[0070] The network card driver 170 is network card control software which the processor 101 of the server computer 100 performs. The flow chart of drawing 6 explains the processing operation.
[0071] A processor receives interruption and the interrupt handler of the network card driver 170 is called.
[0072] A network card driver interrupt handler judges the demand to the remote file system 180, and the usual packet by investigating the status register of the network card 130 (Step D1).
[0073] When it is not the demand to the remote file system 180 (i.e., when the value stored in the status register 132 is except one), (No of Step D1) and the interrupt handler of the network card driver 170 carry out the same operation as the usual network card driver 170.
[0074] Here, a status register 132 judges whether it is 2 (Step D4).
[0075] When the value stored in the status register 132 is 2 (Yes of Step D4), the interrupt handler of the network card driver 170 removes a header (Ethernet frame information) unnecessary to protocol processing of a high order among the data of the packet which the network card 130 transmitted etc., and passes it to protocol drivers (TCP/IP etc.) (Step D5). Since it becomes the same processing as the usual packet reception henceforth, explanation is omitted here.
[0076] When the value stored in the case 132 of a demand, i.e., status register, to the remote file system 180 is 1, (Yes of Step D1) and the interrupt handler of the network card driver 170 take out a file demand from the file demand buffer 133 of the network card 130 (Step D2).
[0077] The worker thread 181 which processes this remote file system demand is started, and a demand is passed (Step D3).
[0078] When the value stored in the status register 132 is except two (No of Step D4) (however, 1 is already excepted), the value of a status register 132 judges whether it is 3 (Step D6).
[0079] When the value of a status register 132 is 3 (Yes of Step D6), the thread which is demanding the DMA transfer is started (Step D7).
[0080] When the value of a status register 132 is except three (No of Step D6) (however, 1 and 2 are already excepted), the value of a status register 132 judges whether it is 4 (Step D8).
[0081] Processing is ended when the value of a status register 132 is except four (No of Step D8) (however, 1, and 2 and 3 are already excepted).
[0082] When the value of a status register 132 is 4 (Yes of Step D8), the usual completion processing of packet transmitting is performed (Step D9).
[0083] By the above and processing operation of the flow chart of drawing 6 , interruption processing of the network card driver 170 is completed now, and the worker thread 181 (remote file system processing is performed) which a processor performs performs henceforth a series of processing operation explained below.
[0084] This processing operation is explained with reference to the flow chart of drawing 7 .
[0085] The passed file manipulation boils the worker thread 181 in a lead, a light, and other operations, and, therefore, it performs the following processings.
[0086] First, the file manipulation to which the worker thread 181 was passed judges whether it is a lead demand (Step E1).
[0087] In a lead demand (Yes of Step E1), the worker thread 181 investigates whether a portion to lead exists in the buffer cache 121 on a primary storage 120 from the file of a file demand, offset, and a data length using the function of the local file system 160 (Step E2).

[0088] When a buffer exists (Yes of Step E2), the address of the corresponding buffer can be acquired.
[0089] The following processings are performed when it exists in the buffer cache 121.
[0090] Operation which locks the corresponding buffer is performed using the function of the local file system 160 (Step E3). When the new operation demand to the buffer comes by this operation, it means performing the exclusion delayed in processing of the demand.
[0091] The worker thread 181 sets the address of the data on the buffer cache 121 which wants to lead the transfer-request register 131, and the address on the transmission buffer 134 of the network card 130 which stores this data (storing), gives the demand which carries out the DMA transfer of the content of the buffer of the buffer cache 121 to the network card 130 to the remote file-processing means 136 of the network card 130 based on this stored address, and waits for the completion (Step E4).
[0092] The remote file-processing means of the network card 130 carries out the DMA transfer of the data which the address of the buffer on the primary storage 120 which prepared the buffer for the transmission buffer 134 on the network card 130, and was passed to it points out in response to the above-mentioned DMA demand (Step E5).
[0093] After a DMA transfer is completed, the remote file-processing means 136 of the network card 130 sets a status register 132 to 3 (DMA transfer completion), and applies interruption to a processor (Step E6).
[0094] The interruption routine of the network card driver 170 is called. An interruption routine recognizes that it is interruption of DMA transfer completion by reading a status register 132. The worker thread 181 for which it is waiting by processing of Step E5 is started, and interruption processing is ended (Step E7).
[0095] The worker thread 181 advances a packet Request to Send to the remote file-processing means 136 of the network card 130 (Step E8).
[0096] Since the data to a remote file system demand (lead demand) are contained in the transmission buffer on the network card 130 by the transfer of (2-3), the rest should just perform transmission.
[0097] The remote file-processing means 136 of the network card 130 creates the header of an Ethernet packet, in order to return the data of a transmission buffer 134 to a transmitting agency (client computer 200 which advanced the lead demand), and it performs transmission (Step E9).
[0098] The worker thread 181 cancels the lock to the buffer of the buffer cache 121 of a primary storage 120 using the function of the local file system 160 (Step E10). Henceforth, other threads, a process, etc. can perform operation to the corresponding buffer.
[0099] The following operations are performed when it does not exist in a buffer (No of Step E2).

[0100] The worker thread 181 investigates the disk block which is needed by read-out operation of a file using the function of the local file system 160. It investigates whether the data required of which portion on a disk exist from a file name and the information on offset. Since the position on a disk 104 is usually managed by the disk block number etc., a disk block number is obtained here (Step E11).
[0101] The worker thread 181 reads the disk block obtained at Step E11, and in order to perform a DMA transfer to the transmission buffer 134 on the network card 130 passed from the interruption routine of the network card driver 170, it calls a disk driver 150 (Step E12).
[0102] A disk driver 150 tells the demand to a disk controller 140, and waits for completion (Step E13).
[0103] The disk demand processing means of a disk controller 140 once reads data from a disk 104, and stores the data in a disk cache 141. The cache data is transmitted to the transmission buffer 134 of the network card 130 to which it was directed at Step E12 (Step E14).
[0104] The disk demand processing means 142 of a disk controller 140 applies interruption to a processor 101 (Step E15).
[0105] The interruption routine of a disk driver 150 starts the worker thread 181 which is Step E13 and is waiting for the completion, and ends interruption processing (Step E16).

[0106] The worker thread 181 advances a data Request to Send to the network card 130 (Step E17).
[0107] This is because transmission could be directed on the network card 130 since the data of the remote file system demand (lead demand) demanded from the client computer 200 were ready on the network card 130.
[0108] The data included in the transmission buffer 134 are used for the remote file-processing means 136 of the network card 130, it creates the answer of a remote file system demand, and transmits it to the client computer 200 (Step E18).
[0109] Using the function of the local file system 160, the worker thread 181 issues read-out operation of a file, and waits for the completion (Step E19).
[0110] Originally there is no need of processing this file read-out demand. The lead demand demanded from the client computer 200 is because it has already processed. However, when the data read from the disk are stored in the buffer cache 121 of the server computer 100 and there is the next access, since the cache effect is expectable by enabling it to reuse, you may store data in the buffer cache 121.
[0111] Then, processing of the worker thread 181 is ended.
[0112] By lead demand, when there is nothing (No of Step E1), in a light demand, a light demand judges whether it is a write-through demand (Step E20).
[0113] In a write-through demand (Yes of Step E20) (i.e., the case of the demand which writes data in a disk immediately), the following processings are performed.
[0114] From the file of a file demand, offset, and a data length, the worker thread 181 calls the function of the local file system 160, and investigates whether the portion which should be carried out a light exists in the buffer cache 121 on a primary storage (Step E21).
[0115] Searching for the address of the buffer with which the local file system 160 corresponds when a buffer exists (Yes of Step E21), the worker thread 181 cancels the buffer using the function of the local file system 160 (Step E22). Since data are overwritten by the light demand which will process this from now on, the data on a primary storage 120 are because it is not necessary to return to a disk 104.
[0116] Using the function of the local file system 160, the worker thread 181 investigates a disk block and obtains the disk block which should carry out a light from the file of a file demand, offset, and a data length (Step E23).
[0117] The worker thread 181 advances a demand and waits for the completion so that the data on the receive buffer 135 of the network card 130 may be written in the disk block obtained at Step E23 using a disk driver 150 (Step E24).
[0118] The disk demand processing means 142 of a disk controller 140 applies interruption to a processor 101, after ending the writing of a disk 104 (Step E25).
[0119] The interrupt handler of a disk driver 150 starts the worker thread 181 which is waiting for completion at Step E24, and ends interruption processing (Step E26).
[0120] Since processing completed the worker thread 181, a demand is given for transmitting the answer to a remote file system demand to the client computer 200 to the network card 130 (Step E27).
[0121] The remote file-processing means 136 of the network card 130 transmits completion of a remote file system demand to the client computer 200 (Step E28).
[0122] The worker thread 181 inspects specification of light processing (Step E29).
[0123] Processing will be ended if it is the mode in which light processing does not use the buffer cache 121 (No of Step E29).
[0124] In order to put data into the buffer cache 121 in the case of the mode in which light processing uses a buffer (Yes of Step E29), the function of the local file system 160 is used for the worker thread 181, it processes a lead demand, and waits for the completion (Step E30).
[0125] Originally it is not necessary to also perform this lead demand. when processing a remote file system demand, the buffer cache 121 is used — bending — it is because it is usually that which is meaningful in the client computer 200
[0126] Therefore, there may not be Step E30.
[0127] Then, processing of the worker thread 181 is ended.

[0128] The following processings are performed when a light demand is not a write-through (No of Step E20).
[0129] The worker thread 181 judges whether the portion which should be carried out a light exists in the buffer cache 121 on a primary storage from the file of a file demand, offset, and a data length using the function of the local file system 160 (Step E31).
[0130] When a buffer exists (Yes of Step E31), the address of the corresponding buffer can be acquired. The following processings are performed when a buffer exists.
[0131] The worker thread 181 performs processing which locks the buffer obtained at Step E31 using the function of the local file system 160 (Step E32).
[0132] The worker thread 181 gives a demand to the remote file-processing means 136 of the network card 130, and waits for the completion so that the address of the data in a receive buffer 135 and the address on the buffer cache 121 may be set to the transfer-request register 131 and the DMA transfer of the data in the receive buffer 135 on the network card 130 may be carried out based on this address to the address on the buffer cache 121 obtained at Step E31 (Step E33).
[0133] By this transfer, the data on the buffer cache 121 will be transposed to the data of a remote file demand (light demand).
[0134] If a DMA transfer is completed, the remote file-processing means 136 of the network card 130 will set a status register to 3, and will apply interruption to a processor 101 (Step E34).
[0135] The interruption routine of the network card driver 170 starts the worker thread 181 for which it waits at Step E33, and completes interruption (Step E35).
[0136] A worker thread cancels the lock of the buffer on 181 and the locked buffer cache 121 (Step E36).
[0137] Then, processing of the worker thread 181 is ended.
[0138] The following processings are performed when there is no buffer (No of Step E31).
[0139] Using the function of the local file system 160, the worker thread 181 secures a buffer on the buffer cache 121 (Step E37), and locks the buffer (Step E32).
[0140] After Step E32, the same processing as the case where there is a buffer is continued.
[0141] As mentioned above, conventionally, the data transfer between the network card 130 and a disk once had to accumulate data to the primary storage 120, and had to perform them to it. However, according to this invention, immediate data can be exchanged between the network card 130 and a disk controller 140 because the network card 130, the network card driver 170, a disk driver 150, and a file system process a remote file system demand in cooperation. Moreover, since the exchange of the data is performed maintaining consistency with the buffer of the file system on a primary storage 120, the function in which the local file system 160 on the server computer 100 operates the data on a disk 104 is maintained.
[0142]
[Effect of the Invention] Since according to this invention it is in a network card and a disk controller and remote file manipulation is processed as a full account was given above, performing protocol processing, file processing, etc. for processing remote file manipulation of the processor of a server computer is lost, and it can assign resources and time to the other processing.
[0143] for example, although the same data flowed twice on the system bus with the conventional technology in order in light processing to transmit data to a primary storage from a network card and to transmit data to a disk from a primary storage further, since data are transmitted to a disk only using an I/O bus from a network card, a transfer of the data using a system bus is unnecessary according to this invention

---

[Translation done.]

* NOTICES *

DESCRIPTION OF DRAWINGS

[Brief Description of the Drawings]
[Drawing 1] The block diagram showing the network file server structure of a system concerning the gestalt of 1 operation of this invention.
[Drawing 2] Drawing showing the data composition of the file demand buffer concerning the gestalt of this operation.
[Drawing 3] The flow chart which shows processing operation in the case of reception of the network card of the gestalt of this operation.
[Drawing 4] The flow chart which shows processing operation in the case of the DMA transfer of the network card concerning the gestalt of this operation.
[Drawing 5] The flow chart which shows processing operation in the case of transmission of a network card with respect to the gestalt of this operation.
[Drawing 6] The flow chart which shows processing operation of the interrupt handler of a network card driver with respect to the gestalt of this operation.
[Drawing 7] The flow chart which shows processing operation of a worker thread with respect to the gestalt of this operation.
[Drawing 8] Drawing showing the conventional network file server structure of a system.
[Description of Notations]
10 -- Server computer
11 -- Processor
12 -- System bus
13 -- PCI bus
14 -- Primary storage
15 -- Buffer cache
16 -- Disk controller
17 -- Disk
18 -- Network card
19 -- Receive buffer
20 -- Network driver
21 -- Protocol stack
22 -- Remote file system
23 -- Local file system
24 -- Network
25 -- Client computer
100 -- Server computer
101 -- Processor
102 -- System bus
103 -- I/O bus
104 -- Disk
120 -- Primary storage
121 -- Buffer KYASHU
122 -- Transmission buffer
123 -- Receive buffer
130 -- Network card
131 -- Transfer-request register
132 -- Status register
133 -- File demand buffer
1330 -- Remote file demand
1331 -- File name
1332 -- Offset
1333 -- Data length
1334 -- Data address
134 -- Transmission buffer
135 -- Receive buffer
136 -- Remote file-processing means
1360 -- Packet analysis section
140 -- Disk controller
141 -- Disk KYASHU
142 -- Disk demand processing means
150 -- Disk driver
160 -- Local file system
161 -- Lock function
162 -- Unlocking function
170 -- Network card driver
180 -- Remote file system
181 -- Worker thread
200 -- Client computer
300 -- Network
1330 -- Remote file demand

[Translation done.]

http://www4.ipdl.jpo.go.jp/cgi-bin/tran_web_cgi_ejje 2003/07/22

(19)日本国特許庁（ＪＰ）　(12) **公開特許公報（Ａ）**　(11)特許出願公開番号
特開2000－47952
（P2000－47952A）
(43)公開日　平成12年２月18日(2000.2.18)

(51)Int.Cl.⁷	識別記号	ＦＩ		テーマコード(参考)
Ｇ０６Ｆ　13/00	３５１	Ｇ０６Ｆ　13/00	３５１Ｅ	５Ｂ０８２
12/00	５１４	12/00	５１４Ａ	５Ｂ０８９

審査請求　未請求　請求項の数８　ＯＬ　（全 18 頁）

(21)出願番号　特願平10－211357

(22)出願日　平成10年７月27日(1998.7.27)

(71)出願人　000003078
株式会社東芝
神奈川県川崎市幸区堀川町72番地
(72)発明者　友田　正憲
東京都青梅市末広町２丁目９番地　株式会社東芝青梅工場内
(74)代理人　100081732
弁理士　大胡　典夫　（外１名）

Ｆターム(参考)　5B082 FA02 FA12
5B089 AA21 AA22 AC05 AD02 AD06 AE09 AF01 AF02 CA11 CB02 CB03 CB11

(54)【発明の名称】　ネットワークファイルサーバシステム、及び同システムに於けるファイル管理方法

(57)【要約】
【課題】　ネットワークアダプタやディスクコントローラ等のＩ／Ｏデバイス間でデータを直接やりとりすることで、サーバ計算機のプロセッサ、主記憶、システムバス資源の使用を最小限に抑え、効率良くＩ／Ｏ処理を行う手段を提供すること。
【解決手段】　サーバ計算機１００上で動作するアプリケーション、ＯＳがディスク上のファイルを、ローカルファイルシステム１６０を通して使用しつつ、ネットワークカード１３０がリモートファイル処理手段１３６により、リモートファイルシステム要求を処理する際、ディスクコントローラ１４０とネットワークカード１３０の間で直接データを転送することで、ディスクコントローラ１４０とネットワークカード１３０間の主記憶１２０を用いたデータ転送の回数を減らすことで、高速な処理を行える。

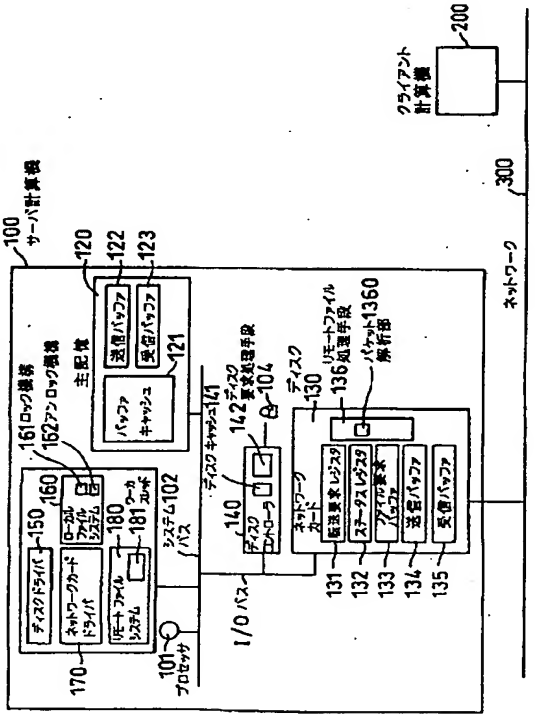

【特許請求の範囲】

【請求項１】　各種アプリケーション等のファイルを提供するサーバ計算機と、このサーバ計算機の提供するファイルにアクセスする複数のクライアント計算機と、上記サーバ計算機と上記クライアント計算機とを接続するネットワークとから成るネットワークファイルサーバシステムであって、

上記サーバ計算機は、

ファイル等の情報を格納する記憶装置と、

この記憶装置を制御する記憶装置制御手段と、

上記クライアント計算機に送受信するパケットのプロトコル処理をし、上記クライアント計算機へ送信するパケットを格納する送信バッファ部と上記クライアント計算機から受信したパケットを格納する受信バッファ部と上記クライアント計算機からのリモートファイルシステム要求に基づいた処理を行うリモートファイル処理部とを設けた通信手段と、

上記記憶装置を管理しこの記憶装置上のファイルを管理して、上記ファイルの上記記憶装置上の位置を問い合わせる要求に対して上記ファイルを格納しているディスクの位置を特定する情報を返す機能を持つローカルファイル制御手段と、

上記クライアント計算機からのリモートファイルシステム要求の内容に基づき上記記憶装置上のファイルを読み書きするリモートファイル制御手段とを備え、

上記リモートファイル処理部は、

上記受信バッファが受信したパケットを解析し、このパケットに含まれている上記クライアント計算機が送信した上記ローカルファイル制御手段の管理するファイルに対する操作要求であるリモートファイルシステム要求を取り出し、

このリモートファイルシステム要求が上記ローカルファイル制御手段の管理する上記記憶装置からのデータ転送を必要とする場合、上記ローカルファイル制御手段にそのファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記記憶装置制御手段に当該ファイルのデータを得られた位置情報に基づいて上記送信バッファに転送することを要求し、このデータが上記送信バッファに格納されたら送信パケットを作成して、上記クライアント計算機へリモートファイルシステム要求の返信を行い、

上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記受信バッファに格納しているデータを上記記憶装置制御手段に直接転送し、上記記憶装置制御手段が先に得た位置に基づき上記受信バッファに格納しているデータを上記記憶装置に書き込み、上記クライアント計算機へリモートファイルシステム要求に対する返信を行い、

上記リモートファイルシステム要求が上記記憶装置からのデータ転送を必要としない場合は、上記リモートファイル制御手段にその要求を渡すことを特徴とするネットワークファイルサーバシステム。

【請求項２】　各種アプリケーション等のファイルを提供するサーバ計算機と、このサーバ計算機の提供するファイルにアクセスする複数のクライアント計算機と、上記サーバ計算機と上記クライアント計算機とを接続するネットワークとから成るネットワークファイルサーバシステムであって、

上記サーバ計算機は、

ファイル等の情報を格納する記憶装置と、

この記憶装置を制御する記憶装置制御手段と、

上記クライアント計算機に送受信するパケットのプロトコル処理をし、上記クライアント計算機へ送信するパケットを格納する送信バッファ部と上記クライアント計算機から受信したパケットを格納する受信バッファ部と上記クライアント計算機からのリモートファイルシステム要求に基づいた処理を行うリモートファイル処理部とを設けた通信手段と、

上記ファイルのデータを上記サーバ計算機の主記憶上のバッファキャッシュ部に格納しておき、上記ファイルに対する操作は、上記バッファキャッシュ部上で行い、上記ファイルのデータをバッファキャッシュ部上に格納している場合には、このファイル要求に対して、上記バッファキャッシュ上の当該ファイルのデータのアドレスを返す機能と、上記記憶装置を管理しこの記憶装置上のファイルを管理して、上記ファイルの上記記憶装置上の位置を問い合わせる要求に対して上記ファイルを格納しているディスクの位置を特定する情報を返す機能とを設けたローカルファイル制御手段と、

上記クライアント計算機からのリモートファイルシステム要求の内容に基づき上記記憶装置上のファイルを読み書きするリモートファイル制御手段とを備え、

上記リモートファイル処理部は、

上記受信バッファが受信したパケットを解析し、このパケットに含まれている上記クライアント計算機が送信した上記ローカルファイル制御手段の管理するファイルに対する操作要求であるリモートファイルシステム要求を取り出し、

上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記バッファキャッシュ部のどの位置に存在するかを問い合わせる要求をし、

上記バッファキャッシュ部上に存在する場合は、当該ファイルのデータのアドレスに基づいてデータをバッファキャッシュ部から上記送信バッファ部にコピーし、当該データを含む送信パケットを作成して、上記クライアント計算機へリモートファイルシステム要求の返信を行い、

上記バッファキャッシュ部に存在しない場合は、上記ローカルファイル制御手段にそのファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記記憶装置制御手段に当該ファイルのデータを得られた位置情報に基づいて上記送信バッファに転送することを要求し、このデータが上記送信バッファに格納されたら送信パケットを作成して、上記クライアント計算機へリモートファイルシステム要求の返信を行い、
上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記バッファキャッシュ部のどの位置に存在するかを問い合わせる要求をし、
上記バッファキャッシュ部上に存在する場合は、当該ファイルのデータのアドレスに基づいて上記受信バッファのデータを書き込み、上記クライアント計算機へリモートファイルシステム要求に対する返信を行い、
上記バッファキャッシュ部上に存在しない場合は、上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記受信バッファに格納しているデータを上記記憶装置制御手段に直接転送し、上記記憶装置制御手段が先に得た位置に基づき上記受信バッファに格納しているデータを上記記憶装置に書き込み、上記クライアント計算機へリモートファイルシステム要求に対する返信を行い、
リモートファイルシステム要求が上記記憶装置からのデータ転送を必要としない場合は、上記リモートファイル制御手段にその要求を渡すことを特徴とするネットワークファイルサーバシステム。

【請求項３】　各種アプリケーション等のファイルを提供するサーバ計算機と、このサーバ計算機の提供するファイルにアクセスする複数のクライアント計算機と、上記サーバ計算機と上記クライアント計算機とを接続するネットワークとから成るネットワークファイルサーバシステムであって、
上記サーバ計算機は、
ファイル等の情報を格納する記憶装置と、
この記憶装置を制御する記憶装置制御手段と、
上記クライアント計算機に送受信するパケットのプロトコル処理をし、上記クライアント計算機へ送信するパケットを格納する送信バッファ部と上記クライアント計算機から受信したパケットを格納する受信バッファ部と上記クライアント計算機からのリモートファイルシステム要求に基づいた処理を行うリモートファイル処理部とを設けた通信手段と、
上記ファイルのデータを上記サーバ計算機の主記憶上のバッファキャッシュ部に格納しておき、上記ファイルに対する操作は、上記バッファキャッシュ部上で行い、上記ファイルのデータをバッファキャッシュ部上に格納している場合には、このファイル要求に対して、上記バッファキャッシュ上の当該ファイルのデータのアドレスを返す機能と、上記ファイルのデータをバッファキャッシュ部上に格納していない場合、上記ファイル要求に基づいて、当該ファイルを格納する上記バッファキャッシュ部を確保し、このアドレスを返す機能と、上記記憶装置を管理しこの記憶装置上のファイルを管理して、上記ファイルの上記記憶装置上の位置を問い合わせる要求に対して上記ファイルを格納しているディスクの位置を特定する情報を返す機能とを設けたローカルファイル制御手段と、
上記クライアント計算機からのリモートファイルシステム要求の内容に基づき上記記憶装置上のファイルを読み書きするリモートファイル制御手段とを備え、上記リモートファイル処理部は、
上記受信バッファが受信したパケットを解析し、このパケットに含まれている上記クライアント計算機が送信した上記ローカルファイル制御手段の管理するファイルに対する操作要求であるリモートファイルシステム要求を取り出し、
上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記バッファキャッシュ部のどの位置に存在するかを問い合わせる要求をし、
上記バッファキャッシュ部上に存在する場合は、当該ファイルのデータのアドレスに基づいてデータをバッファキャッシュ部から上記送信バッファ部にコピーし、当該データを含む送信パケットを作成して、上記クライアント計算機へリモートファイルシステム要求の返信を行い、
上記バッファキャッシュ部に存在しない場合は、上記ローカルファイル制御手段にそのファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記記憶装置制御手段に当該ファイルのデータを得られた位置情報に基づいて上記送信バッファに転送することを要求し、このデータが上記送信バッファに格納されたら送信パケットを作成して、上記クライアント計算機へリモートファイルシステム要求の返信を行い、上記ローカルファイル制御手段が確保したバッファキャッシュ部のアドレスに上記データを転送し、
上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記バッファキャッシュ部のどの位置に存在するかを問い合わせる要求をし、
上記バッファキャッシュ部上に存在する場合は、当該ファイルのデータのアドレスに基づいて上記受信バッファのデータを書き込み、上記クライアント計算機へリモートファイルシステム要求に対する返信を行い、
上記バッファキャッシュ部上に存在しない場合は、上記リモートファイルシステム要求が上記記憶装置へのデー

タ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記受信バッファに格納しているデータを上記記憶装置制御手段に直接転送し、上記記憶装置制御手段が先に得た位置に基づき上記受信バッファに格納しているデータを上記記憶装置に書き込み、上記クライアント計算機へリモートファイルシステム要求に対する返信を行い、上記ローカルファイル制御手段が確保したバッファキャッシュ部のアドレスに上記受信バッファに格納しているデータを転送し、

リモートファイルシステム要求が上記記憶装置からのデータ転送を必要としない場合は、上記リモートファイル制御手段にその要求を渡すことを特徴とするネットワークファイルサーバシステム。

【請求項４】　各種アプリケーション等のファイルを提供するサーバ計算機と、このサーバ計算機の提供するファイルにアクセスする複数のクライアント計算機と、上記サーバ計算機と上記クライアント計算機とを接続するネットワークとから成るネットワークファイルサーバシステムであって、

上記サーバ計算機は、

ファイル等の情報を格納する記憶装置と、

この記憶装置を制御する記憶装置制御手段と、

上記クライアント計算機に送受信するパケットのプロトコル処理をし、上記クライアント計算機へ送信するパケットを格納する送信バッファ部と上記クライアント計算機から受信したパケットを格納する受信バッファ部とを設け、上記クライアント計算機からのリモートファイルシステム要求に基づき処理を行うリモートファイル処理部とを設けた通信手段と、

上記記憶装置を管理しこの記憶装置上のファイルを管理して、上記ファイルの上記記憶装置上の位置を問い合わせる要求に対して上記ファイルを格納しているディスクの位置を特定する情報を返す機能と、上記ファイルへの書き込み、削除、作成等の操作を行う際に、このファイルを格納する記憶装置上の位置情報とこのファイルを特定する情報であるファイル位置情報を上記通信手段に通知する機能とを備えたローカルファイル制御手段と、

上記クライアント計算機からのリモートファイルシステム要求の内容に基づき上記記憶装置上のファイルを読み書きするリモートファイル制御手段とを備え、上記リモートファイル処理部は、

上記受信バッファが受信したパケットを解析し、このパケットに含まれている上記クライアント計算機が送信した上記ローカルファイル制御手段の管理するファイルに対する操作要求であるリモートファイルシステム要求を取り出し、

このリモートファイルシステム要求が上記ローカルファイル制御手段の管理する上記記憶装置からのデータ転送を必要とする場合、上記ファイル位置情報に基づき一致するファイルがあるかを検索し、一致した場合、上記記憶装置制御手段に上記ファイル位置情報に基づき上記記憶装置上のデータを上記送信バッファに転送することを要求し、このデータが上記送信バッファに格納されたら送信パケットを作成して、上記クライアント計算機へリモートファイルシステム要求の返信を行い、

一致しない場合、上記ローカルファイル制御手段にそのファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記記憶装置制御手段に当該ファイルのデータを得られた位置情報に基づいて上記送信バッファに転送することを要求し、このデータが上記送信バッファに格納されたら送信パケットを作成して、上記クライアント計算機へリモートファイルシステム要求の返信を行い、

上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ファイル位置情報に基づき一致するファイルがあるかを検索し、一致した場合、上記ファイル位置情報に基づき上記受信バッファに格納しているデータを上記記憶装置制御手段に転送し、上記記憶装置制御手段は上記ファイル位置情報に基づき上記受信バッファに格納しているデータを上記記憶装置上に書き込み、上記クライアント計算機へリモートファイルシステム要求に対する返信を行い、

一致しない場合、上記ローカルファイル制御手段に当該ファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記受信バッファに格納しているデータを上記記憶装置制御手段に直接転送し、上記記憶装置制御手段が先に得た位置に基づき上記受信バッファに格納しているデータを書き込み、上記クライアント計算機へリモートファイルシステム要求の返信を行い、

リモートファイルシステム要求が上記記憶装置からのデータ転送を必要としない場合は、上記リモートファイル制御手段にその要求を渡すことを特徴とするネットワークファイルサーバシステム。

【請求項５】　各種アプリケーション等のファイルを提供するサーバ計算機と、このサーバ計算機の提供するファイルにアクセスする複数のクライアント計算機と、上記サーバ計算機と上記クライアント計算機とを接続するネットワークとから成るネットワークファイルサーバシステムに於けるファイル管理方法であって、

上記サーバ計算機は、

ファイル等の情報を格納する記憶装置と、

この記憶装置を制御する記憶装置制御手段と、

上記クライアント計算機に送受信するパケットのプロトコル処理をし、上記クライアント計算機へ送信するパケットを格納する送信バッファ部と上記クライアント計算機から受信したパケットを格納する受信バッファ部と上記クライアント計算機からのリモートファイルシステム要求に基づいた処理を行うリモートファイル処理部とを設けた通信手段と、

上記記憶装置を管理しこの記憶装置上のファイルを管理して、上記ファイルの上記記憶装置上の位置を問い合わせる要求に対して上記ファイルを格納しているディスクの位置を特定する情報を返す機能を持つローカルファイル制御手段と、
上記クライアント計算機からのリモートファイルシステム要求の内容に基づき上記記憶装置上のファイルを読み書きするリモートファイル制御手段とを備え、
上記リモートファイル処理部は、
上記受信バッファが受信したパケットを解析し、このパケットに含まれている上記クライアント計算機が送信した上記ローカルファイル制御手段の管理するファイルに対する操作要求であるリモートファイルシステム要求を取り出し、
このリモートファイルシステム要求が上記ローカルファイル制御手段の管理する上記記憶装置からのデータ転送を必要とする場合、上記ローカルファイル制御手段にそのファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記記憶装置制御手段に当該ファイルのデータを得られた位置情報に基づいて上記送信バッファに転送することを要求し、このデータが上記送信バッファに格納されたら送信パケットを作成して、上記クライアント計算機へリモートファイルシステム要求の返信を行い、
上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記受信バッファに格納しているデータを上記記憶装置制御手段に直接転送し、上記記憶装置制御手段が先に得た位置に基づき上記受信バッファに格納しているデータを上記記憶装置に書き込み、上記クライアント計算機へリモートファイルシステム要求に対する返信を行い、
上記リモートファイルシステム要求が上記記憶装置からのデータ転送を必要としない場合は、上記リモートファイル制御手段にその要求を渡すことを特徴とするネットワークファイルサーバシステムに於けるファイル管理方法。

【請求項６】　各種アプリケーション等のファイルを提供するサーバ計算機と、このサーバ計算機の提供するファイルにアクセスする複数のクライアント計算機と、上記サーバ計算機と上記クライアント計算機とを接続するネットワークとからなるネットワークファイルサーバシステムのファイル管理方法であって、
上記サーバ計算機は、
ファイル等の情報を格納する記憶装置と、
この記憶装置を制御する記憶装置制御手段と、
上記クライアント計算機に送受信するパケットのプロトコル処理をし、上記クライアント計算機へ送信するパケットを格納する送信バッファ部と上記クライアント計算機から受信したパケットを格納する受信バッファ部と上記クライアント計算機からのリモートファイルシステム要求に基づいた処理を行うリモートファイル処理部とを設けた通信手段と、
上記ファイルのデータを上記サーバ計算機の主記憶上のバッファキャッシュ部に格納しておき、上記ファイルに対する操作は、上記バッファキャッシュ部上で行い、上記ファイルのデータをバッファキャッシュ部上に格納している場合には、このファイル要求に対して、上記バッファキャッシュ上の当該ファイルのデータのアドレスを返す機能と、上記記憶装置を管理しこの記憶装置上のファイルを管理して、上記ファイルの上記記憶装置上の位置を問い合わせる要求に対して上記ファイルを格納しているディスクの位置を特定する情報を返す機能とを設けたローカルファイル制御手段と、
上記クライアント計算機からのリモートファイルシステム要求の内容に基づき上記記憶装置上のファイルを読み書きするリモートファイル制御手段とを備え、上記リモートファイル処理部は、
上記受信バッファが受信したパケットを解析し、このパケットに含まれている上記クライアント計算機が送信した上記ローカルファイル制御手段の管理するファイルに対する操作要求であるリモートファイルシステム要求を取り出し、
上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記バッファキャッシュ部のどの位置に存在するかを問い合わせる要求をし、
上記バッファキャッシュ部上に存在する場合は、当該ファイルのデータのアドレスに基づいてデータをバッファキャッシュ部から上記送信バッファ部にコピーし、当該データを含む送信パケットを作成して、上記クライアント計算機へリモートファイルシステム要求の返信を行い、
上記バッファキャッシュ部に存在しない場合は、上記ローカルファイル制御手段にそのファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記記憶装置制御手段に当該ファイルのデータを得られた位置情報に基づいて上記送信バッファに転送することを要求し、このデータが上記送信バッファに格納されたら送信パケットを作成して、上記クライアント計算機へリモートファイルシステム要求の返信を行い、
上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記バッファキャッシュ部のどの位置に存在するかを問い合わせる要求をし、
上記バッファキャッシュ部上に存在する場合は、当該ファイルのデータのアドレスに基づいて上記受信バッファのデータを書き込み、上記クライアント計算機へリモートファイルシステム要求に対する返信を行い、

上記バッファキャッシュ部上に存在しない場合は、上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記受信バッファに格納しているデータを上記記憶装置制御手段に直接転送し、上記記憶装置制御手段が先に得た位置に基づき上記受信バッファに格納しているデータを上記記憶装置に書き込み、上記クライアント計算機へリモートファイルシステム要求に対する返信を行い、
リモートファイルシステム要求が上記記憶装置からのデータ転送を必要としない場合は、上記リモートファイル制御手段にその要求を渡すことを特徴とするネットワークファイルサーバシステムに於けるファイル管理方法。

【請求項７】　各種アプリケーション等のファイルを提供するサーバ計算機と、このサーバ計算機の提供するファイルにアクセスする複数のクライアント計算機と、上記サーバ計算機と上記クライアント計算機とを接続するネットワークとからなるネットワークファイルサーバシステムのファイル管理方法であって、
上記サーバ計算機は、
ファイル等の情報を格納する記憶装置と、
この記憶装置を制御する記憶装置制御手段と、
上記クライアント計算機に送受信するパケットのプロトコル処理をし、上記クライアント計算機へ送信するパケットを格納する送信バッファ部と上記クライアント計算機から受信したパケットを格納する受信バッファ部と上記クライアント計算機からのリモートファイルシステム要求に基づいた処理を行うリモートファイル処理部とを設けた通信手段と、
上記ファイルのデータを上記サーバ計算機の主記憶上のバッファキャッシュ部に格納しておき、上記ファイルに対する操作は、上記バッファキャッシュ部上で行い、上記ファイルのデータをバッファキャッシュ部上に格納している場合には、このファイル要求に対して、上記バッファキャッシュ上の当該ファイルのデータのアドレスを返す機能と、上記ファイルのデータをバッファキャッシュ部上に格納していない場合、上記ファイル要求に基づいて、当該ファイルを格納する上記バッファキャッシュ部を確保し、このアドレスを返す機能と、上記記憶装置を管理しこの記憶装置上のファイルを管理して、上記ファイルの上記記憶装置上の位置を問い合わせる要求に対して上記ファイルを格納しているディスクの位置を特定する情報を返す機能とを設けたローカルファイル制御手段と、
上記クライアント計算機からのリモートファイルシステム要求の内容に基づき上記記憶装置上のファイルを読み書きするリモートファイル制御手段とを備え、
上記リモートファイル処理部は、
上記受信バッファが受信したパケットを解析し、このパケットに含まれている上記クライアント計算機が送信した上記ローカルファイル制御手段の管理するファイルに対する操作要求であるリモートファイルシステム要求を取り出し、
上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記バッファキャッシュ部のどの位置に存在するかを問い合わせる要求をし、
上記バッファキャッシュ部上に存在する場合は、当該ファイルのデータのアドレスに基づいてデータをバッファキャッシュ部から上記送信バッファ部にコピーし、当該データを含む送信パケットを作成して、上記クライアント計算機へリモートファイルシステム要求の返信を行い、
上記バッファキャッシュ部に存在しない場合は、上記ローカルファイル制御手段にそのファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記記憶装置制御手段に当該ファイルのデータを得られた位置情報に基づいて上記送信バッファに転送することを要求し、このデータが上記送信バッファに格納されたら送信パケットを作成して、上記クライアント計算機へリモートファイルシステム要求の返信を行い、上記ローカルファイル制御手段が確保したバッファキャッシュ部のアドレスに上記データを転送し、
上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記バッファキャッシュ部のどの位置に存在するかを問い合わせる要求をし、
上記バッファキャッシュ部上に存在する場合は、当該ファイルのデータのアドレスに基づいて上記受信バッファのデータを書き込み、上記クライアント計算機へリモートファイルシステム要求に対する返信を行い、
上記バッファキャッシュ部上に存在しない場合は、上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記受信バッファに格納しているデータを上記記憶装置制御手段に直接転送し、上記記憶装置制御手段が先に得た位置に基づき上記受信バッファに格納しているデータを上記記憶装置に書き込み、上記クライアント計算機へリモートファイルシステム要求に対する返信を行い、上記ローカルファイル制御手段が確保したバッファキャッシュ部のアドレスに上記受信バッファに格納しているデータを転送し、
リモートファイルシステム要求が上記記憶装置からのデータ転送を必要としない場合は、上記リモートファイル制御手段にその要求を渡すことを特徴とするネットワークファイルサーバシステムに於けるファイル管理方法。

【請求項８】　各種アプリケーション等のファイルを提供するサーバ計算機と、このサーバ計算機の提供するフ

ファイルにアクセスする複数のクライアント計算機と、上記サーバ計算機と上記クライアント計算機とを接続するネットワークとからなるネットワークファイルサーバシステムのファイル管理方法であって、
上記サーバ計算機は、
ファイル等の情報を格納する記憶装置と、
この記憶装置を制御する記憶装置制御手段と、
上記クライアント計算機に送受信するパケットのプロトコル処理をし、上記クライアント計算機へ送信するパケットを格納する送信バッファ部と上記クライアント計算機から受信したパケットを格納する受信バッファ部とを設け、上記クライアント計算機からのリモートファイルシステム要求に基づき処理を行うリモートファイル処理部とを設けた通信手段と、
上記記憶装置を管理しこの記憶装置上のファイルを管理して、上記ファイルの上記記憶装置上の位置を問い合わせる要求に対して上記ファイルを格納しているディスクの位置を特定する情報を返す機能と、上記ファイルへの書き込み、削除、作成等の操作を行う際に、このファイルを格納する記憶装置上の位置情報とこのファイルを特定する情報であるファイル位置情報を上記通信手段に通知する機能とを備えたローカルファイル制御手段と、
上記クライアント計算機からのリモートファイルシステム要求の内容に基づき上記記憶装置上のファイルを読み書きするリモートファイル制御手段とを備え、上記リモートファイル処理部は、
上記受信バッファが受信したパケットを解析し、このパケットに含まれている上記クライアント計算機が送信した上記ローカルファイル制御手段の管理するファイルに対する操作要求であるリモートファイルシステム要求を取り出し、
このリモートファイルシステム要求が上記ローカルファイル制御手段の管理する上記記憶装置からのデータ転送を必要とする場合、上記ファイル位置情報に基づき一致するファイルがあるかを検索し、一致した場合、上記記憶装置制御手段に上記ファイル位置情報に基づき上記記憶装置上のデータを上記送信バッファに転送することを要求し、このデータが上記送信バッファに格納されたら送信パケットを作成して、上記クライアント計算機へリモートファイルシステム要求の返信を行い、
一致しない場合、上記ローカルファイル制御手段にそのファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記記憶装置制御手段に当該ファイルのデータを得られた位置情報に基づいて上記送信バッファに転送することを要求し、このデータが上記送信バッファに格納されたら送信パケットを作成して、上記クライアント計算機へリモートファイルシステム要求の返信を行い、
上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ファイル位置情報に基づき一致するファイルがあるかを検索し、一致した場合、上記ファイル位置情報に基づき上記受信バッファに格納しているデータを上記記憶装置制御手段に転送し、
上記記憶装置制御手段は上記ファイル位置情報に基づき上記受信バッファに格納しているデータを上記記憶装置上に書き込み、上記クライアント計算機へリモートファイルシステム要求に対する返信を行い、
一致しない場合、上記ローカルファイル制御手段に当該ファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記受信バッファに格納しているデータを上記記憶装置制御手段に直接転送し、上記記憶装置制御手段が先に得た位置に基づき上記受信バッファに格納しているデータを書き込み、上記クライアント計算機へリモートファイルシステム要求の返信を行い、
リモートファイルシステム要求が上記記憶装置からのデータ転送を必要としない場合は、上記リモートファイル制御手段にその要求を渡すことを特徴とするネットワークファイルサーバシステムに於けるファイル管理方法。

【発明の詳細な説明】

【０００１】

【発明の属する技術分野】本発明は、複数のクライアント計算機から公衆通信網や有線、無線のＬＡＮ（Ｌｏｃａｌ　Ａｒｅａ　Ｎｅｔｗｏｒｋ）等のネットワークを介してサーバ計算機上のファイルにアクセスし、データの送受信を行うネットワークファイルサーバシステム、及びネットワークファイルサーバシステムに於けるファイル管理方法に関する。

【０００２】

【従来の技術】従来、図８に示すように、ネットワークファイルサーバ１０では、クライアント計算機２５とネットワークファイルサーバ１０の間で情報をやり取りするものであった。即ち、

（１）クライアント計算機２５から、ＬＡＮ等のネットワーク２４を経由し、ファイル操作要求を格納したパケットがネットワークファイルサーバ１０（以下、サーバ計算機１０と呼ぶ）のネットワークカード１８に届く。

【０００３】（２）ネットワークドライバ２０が、サーバ計算機１０のネットワークカード１８に届いたパケットをネットワークカード１８の受信バッファ１９から、主記憶１４に転送する。

【０００４】（３）ＴＣＰ／ＩＰ等の通信プロトコルを解析するプロトコルスタック２１が、パケットの内容を解析し、パケットに格納されたファイル操作要求を取り出して、リモートファイルシステム２２に渡す。

【０００５】（４）リモートファイルシステム２２は、ファイル操作要求をローカルファイルシステム２３に渡す。ローカルファイルシステム２３は、サーバ計算機１０のディスク１７を管理するファイルシステムである。

【０００６】（５）ローカルファイルシステム２３がファイル操作要求を処理する。その結果をリモートファイ

ルシステム２２に返す。

【０００７】（６）リモートファイルシステム２２は、結果を格納したパケットを作成し、プロトコルスタック２１、ネットワークカード１８、ネットワーク２４を経由して、結果をクライアント計算機２５に送信する。

【０００８】到着したパケットを処理するソフトウェアは、ネットワークドライバ２０、プロトコルスタック２１、リモートファイルシステム２２、ローカルファイルシステム２３である。これらは、ディスク等の記憶装置上にインストールされているものとする。

【０００９】サーバ計算機１０のプロセッサ１１が、主記憶１４上でこれらのソフトウェアを実行する。ファイル操作要求の処理では、主記憶１４を経由して、ディスク１７とネットワークカード１８間のデータのやり取りを行う。

【００１０】これまでのサーバ計算機１０に於いて、信頼性の高いデータ送受信を実現するプロトコルスタック２１の処理に時間がかかり、プロセッサ資源を多く消費していた。

【００１１】また、ネットワークファイルサービス等に於いては、ディスクコントローラ１６、ネットワークカード１８を用いてデータのやりとりが発生する。どちらのデバイスも、サーバ計算機１０のＩ／Ｏバス１３（ＰＣＩバス等で実現する）に接続されている。

【００１２】そのために、これまでは、ネットワークカード１８、ディスクコントローラ１６等のデバイスを制御するソフトウェア（サーバ計算機のプロセッサが実行する）が、データを主記憶にいったん転送し、処理を行った後、各デバイスへデータをさらに転送していたものであった。

【００１３】

【発明が解決しようとする課題】上述したように、従来のサーバ計算機１０にあっては、信頼性の高いデータ送受信を実現するプロトコルスタック２１の処理に時間がかかり、プロセッサ資源を多く消費していた。また、ネットワークファイルサービス等に於いては、ディスクコントローラ１６、ネットワークカード１８を用いてデータのやりとりが発生するものであった。どちらのデバイスも、サーバ計算機１０のＩ／Ｏバス１３（ＰＣＩバス等で実現する）に接続されている。

【００１４】そのために、従来は、ネットワークカード１８、ディスクコントローラ１６等のデバイスを制御するソフトウェア（サーバ計算機のプロセッサが実行する）が、データを主記憶にいったん転送し、処理を行った後、各デバイスへデータを更に転送していたものであった。

【００１５】そこで、本発明は上記事情を考慮して成されたもので、上記不具合を解消し、複数のクライアント計算機から公衆通信網や有線、無線のＬＡＮ等のネットワークを介してサーバ計算機上のファイルにアクセスし、データの送受信を行うネットワークファイルサーバシステムにあって、ネットワークアダプタやディスクコントローラ等のＩ／Ｏデバイス間でデータを直接やりとりすることで、サーバ計算機のプロセッサ、主記憶、システムバス資源の使用を最小限に抑え、効率良くＩ／Ｏ処理を行えるネットワークファイルサーバシステム、及びネットワークファイルサーバシステムに於けるファイル管理方法を提供することを目的とする。

【００１６】

【課題を解決するための手段】本発明は上記目的を達成する為、本発明のネットワークファイルサーバシステムは、各種アプリケーション等のファイルを提供するサーバ計算機と、このサーバ計算機の提供するファイルにアクセスする複数のクライアント計算機と、上記サーバ計算機と上記クライアント計算機とを接続するネットワークとからなるネットワークファイルサーバシステムであって、上記サーバ計算機は、ファイル等の情報を格納する記憶装置と、この記憶装置を制御する記憶装置制御手段と、上記クライアント計算機に送受信するパケットのプロトコル処理をし、上記クライアント計算機へ送信するパケットを格納する送信バッファ部と上記クライアント計算機から受信したパケットを格納する受信バッファ部と上記クライアント計算機からのリモートファイルシステム要求に基づいた処理を行うリモートファイル処理部とを設けた通信手段と、上記記憶装置を管理しこの記憶装置上のファイルを管理して、上記ファイルの上記記憶装置上の位置を問い合わせる要求に対して上記ファイルを格納しているディスクの位置を特定する情報を返す機能を持つローカルファイル制御手段と、上記クライアント計算機からのリモートファイルシステム要求の内容に基づき上記記憶装置上のファイルを読み書きするリモートファイル制御手段とを備え、上記リモートファイル処理部は、上記受信バッファが受信したパケットを解析し、このパケットに含まれている上記クライアント計算機が送信した上記ローカルファイル制御手段の管理するファイルに対する操作要求であるリモートファイルシステム要求を取り出し、このリモートファイルシステム要求が上記ローカルファイル制御手段の管理する上記記憶装置からのデータ転送を必要とする場合、上記ローカルファイル制御手段にそのファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記記憶装置制御手段に当該ファイルのデータを得られた位置情報に基づいて上記送信バッファに転送することを要求し、このデータが上記送信バッファに格納されたら送信パケットを作成して、上記クライアント計算機へリモートファイルシステム要求の返信を行い、上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記記憶装置制御手段にファイルのデータ

を得られた位置情報に基づいて上記送信バッファに転送することを要求し、このデータが上記送信バッファに格納されたら送信パケットを作成して上記クライアント計算機へリモートファイルシステム要求の返信を行い、上記リモートファイルシステム要求が上記記憶装置へのデータ転送を必要とする場合、上記ローカルファイル制御手段に当該ファイルが上記記憶装置のどの位置に存在するかを問い合わせる要求をし、上記受信バッファに格納しているデータを上記記憶装置制御手段に直接転送し、上記記憶装置制御手段が先に得た位置に基づき上記受信バッファに格納しているデータを上記記憶装置に書き込み、上記クライアント計算機へリモートファイルシステム要求に対する返信を行い、上記リモートファイルシステム要求が上記記憶装置からのデータ転送を必要としない場合は、上記リモートファイル制御手段にその要求を渡すように構成したことを特徴とする。

【００１７】このような構成によれば、サーバ計算機上で動作するアプリケーション、オペレーティングシステム（ＯＳ）がディスク上のファイルを、ローカルファイルシステムを通して使用しつつ、ネットワークカードが、リモートファイルシステム要求を処理する際に、ディスクコントローラとネットワークカードの間で直接データを転送することで、ディスクコントローラとネットワークカード間の主記憶を用いたデータ転送の回数を減らすことで、高速な処理を行うことができる。

【００１８】さらに、ネットワークカードが解釈したパケットのうち、ネットワークファイルシステム要求のみを、本発明で提案するリモートファイルシステム（サーバ計算機のプロセッサが実行する）に送る。このとき、要求のみをサーバ計算機の主記憶に送り、ファイルのデータ等をネットワークカードとディスクコントローラの間で直接ＤＭＡ転送することにより、これまでよりデータ転送の回数を減らすことができる。

【００１９】この構成に加えて、上記ローカルファイル制御手段が、要求のあったファイルを格納する記憶装置上の位置情報とこのファイルを特定する情報であるファイル位置情報を上記通信手段に通知する機能を備えれば、更に、高速にファイルのディスク位置情報を得ることができる。

【００２０】また、この構成に加えて、サーバ計算機上で動作するアプリケーション、ＯＳがディスク上のファイルを、ローカルファイルシステムを通して使用しつつ、ネットワークカードが、リモートファイルシステム要求を処理する際に、ローカルファイルシステムが管理する主記憶上のバッファキャッシュのデータをネットワークカードに直接転送することで、高速な処理を行うことができ、更に、リモートファイルシステム要求で発生したディスクとのデータのやりとりをバッファキャッシュに格納することで、次に同じファイルへの要求（サーバ計算機上のアプリケーションがローカルファイルシステムを通して、あるいは、クライアント計算機がリモートファイルシステム要求として）に対し、バッファキャッシュ上のデータを使用することができる。

【００２１】

【発明の実施の形態】以下、本発明の一実施の形態について、図面を参照して説明する。

【００２２】図１は、本実施形態に係わるネットワークファイルサーバシステムの構成を示したブロック図である。本実施形態の説明に必要な構成を示し、他の構成は省略している。

【００２３】クライアント計算機２００は、公衆通信網や有線、無線のＬＡＮ等のネットワーク３００によってサーバ計算機１００と接続されており、サーバ計算機１００上のファイルにアクセスする。このファイルは、サーバ計算機上にインストールされた各種アプリケーション、またはその他のアプリケーション等に対応したファイルである。

【００２４】プロセッサ１０１は、サーバ計算機１００の各部の制御を行うものである。

【００２５】システムバス１０２は、主記憶１２０等とプロセッサ１０１を接続し各種データ転送するものである。

【００２６】Ｉ／Ｏバス１０３は、ネットワークカード１３０、ディスクコントローラ１４０、図示しないキーボード、マウス等の入力手段、ディスプレイ等のＩ／Ｏ機器とシステムバス１０２を接続し各種データを転送する。

【００２７】主記憶１２０は、サーバ計算機１００の主記憶であり、バッファキャッシュ１２１、送信バッファ１２２、受信バッファ１２３を備える。

【００２８】リモートファイルシステム１８０、ローカルファイルシステム１６０、ネットワークカードドライバ１７０、ディスクドライバ１５０は、ソフトウェアであり、ディスク１０４等の記憶装置上に保存され、プロセッサ１０１により実行される。

【００２９】リモートファイルシステム１８０は、ワーカースレッド１８１によりファイルシステム要求の内容に基づきサーバ計算機１００上のファイルを読み書きする等の処理を行う。

【００３０】ローカルファイルシステム１６０は、サーバ計算機１００が備えるディスク１０４を管理し、ロック機能１６１とアンロック機能１６２を備える。ロック機能１６１とアンロック機能１６２の機能については後述する。

【００３１】ネットワークカードドライバ１７０は、ネットワークカード１３０を制御するものである。

【００３２】ディスクドライバ１５０は、ディスクコントローラ１４０によりディスク１０４を制御する。

【００３３】サーバ計算機１００は、クライアント計算機２００とデータの送受信を行うためのプロトコル処理

を行うネットワークカード１３０を備える。このネットワークカード１３０は、サーバ計算機１００とクライアント計算機２００間で送受信するパケットのプロトコル処理を行った結果、そのパケットがクライアント計算機２００からサーバ計算機１００上のファイルを読み書き等するファイルシステム要求でない場合は、ネットワークカードドライバ１７０と連携して、通常のネットワークカードと同様の処理を行う。

【００３４】また、ネットワークカード１３０は、上記送受信するパケットがファイルシステム要求の場合、サーバ計算機１００上で動作するネットワークカードドライバ１７０と、リモートファイルシステム１８０上のワーカースレッド１８１と協調して、ファイルシステム要求の内容に基づきサーバ計算機１００上のファイルを読み書きする等の処理を行う。

【００３５】上記ネットワークカード１３０は、以下のものから構成される。

【００３６】受信パケットのプロトコル処理を実行し、その受信パケットがファイルシステム要求の場合には、その処理を行うリモートファイル処理手段１３６と、リモートファイル処理手段１３６が解析したパケットの内容を格納するファイル要求バッファ１３３、受信パケットが通常のパケットか、或いはファイルシステム要求か等を示す情報を格納するステータスレジスタ１３２、他の計算機から送信されたパケットをいったん格納する受信バッファ１３５と、送信すべきパケットを蓄積する送信バッファ１３４と転送要求レジスタ１３１とからなる。

【００３７】転送要求レジスタ１３１は、データの格納元のアドレスとそこからデータ転送し、そのデータを格納する先のアドレスの情報が格納される。例えば、送信データがバッファキャッシュ１２１上にある場合は、そのデータのバッファキャッシュ１２１上のアドレスと、そのデータの転送先である送信バッファ１３４上のアドレスが格納される。受信データが受信バッファ１３５上にある場合、そのデータの受信バッファ１３５上のアドレスと、そのデータの転送先であるバッファキャッシュ１２１上のアドレスが格納される。

【００３８】ステータスレジスタ１３２に格納するステータスを示す値は、ここでは次の通りとする。１はファイルシステムのリードライト要求受信を示し、２は通常パケット受信を示し、３はＤＭＡ転送完了を示し、そして、４は通常のパケット送信処理を示す。

【００３９】ファイル要求バッファ１３３は、図２に示すようにリモートファイルシステム要求１３３０（リード、ライト、その他）、対象となるファイル名１３３１、そのオフセット１３３２、データ長１３３３、データアドレス１３３４から成るものである。

【００４０】ローカルファイルシステム１６０は、サーバ計算機１００が備えるディスクを管理する。即ち、ディスク１０４上にファイルを格納し、ファイルの作成、リード、ライト、削除等の機能を提供する。主記憶１２０上にバッファキャッシュ１２１を作成し、ファイルのデータをキャッシュする。更に、以下の機能を備えるものである。

【００４１】１．ファイル名、オフセット、データ長を入力として、そのファイルの該当する内容がバッファキャッシュ１２１にあるかどうかを判定する。バッファキャッシュ１２１にある場合には、そのバッファのアドレスを返す。

【００４２】２．バッファのアドレスを入力として、該当するバッファへのファイル操作要求を禁止するロック機能１６１と、それを解除するアンロック機能１６２。

【００４３】３．ファイル名、オフセット、データ長を入力として、該当するデータを格納しているディスクの位置（ディスクブロック）を返す。

【００４４】ディスクコントローラ１４０は、ディスク要求処理手段１４２と、ディスク１０４から読み出した、あるいは、ディスク１０４へ書き込むデータをいったん格納するディスクキャッシュ１４１を備える。

【００４５】サーバ計算機１００が実行するネットワークカードドライバ１７０は、以下の機能を備える。

【００４６】１．ネットワークカード１３０からの割り込みを処理する。

【００４７】２．通常のパケットの送受信を行う。

【００４８】３．主記憶１２０上に、送信バッファ１２２、受信バッファ１２３を確保する。

【００４９】サーバ計算機１００のプロセッサ１０１が実行するワーカースレッド１８１は、リモートファイルシステム要求を受け、その処理を担当する。

【００５０】リモートファイルシステム要求は、クライアント計算機２００が、サーバ計算機１００へ要求を送信するところから処理が始まる。以下、クライアント計算機２００がリモートファイルシステム要求を出し、その要求をサーバ計算機１００がどのように処理するかを図３のフローチャートにより説明する。

【００５１】まず、ネットワークカード１３０のリモートファイル処理手段１３６は、クライアント計算機２００からパケットの受信があると、以下の動作を行う。ここでは、通信にイーサネット、プロトコルにＴＣＰ／ＩＰを用いている例を説明する。

【００５２】ネットワークカード１３０宛てのパケットが、ネットワーク３００上に発信された場合、そのパケットを受信バッファ１３５に蓄積する（ステップＡ１）。

【００５３】受信バッファ１３５に蓄積したパケットを解析し、ＴＣＰ／ＩＰのプロトコル処理を行うパケット解析部１３６０がパケットのデータ部を解析し、処理できるプロトコルかどうか判定する（ステップＡ２）。

【００５４】処理できないプロトコルの場合（ステップ

Ａ２のＮｏ）、ステップＡ８の処理を行う。

【００５５】処理できるプロトコルの場合（ステップＡ２のＹｅｓ）、パケット解析部１３６０によりプロトコル処理を行う（ステップＡ３）。

【００５６】次に、リモートファイルシステム１８０への要求かどうかを判定する（ステップＡ４）。ここで、リモートファイルシステム１８０への要求は、あらかじめ定められたＴＣＰ／ＩＰのポートに対し送信されるので、パケットのポート番号を監視すれば、容易に判定することができる。

【００５７】リモートファイルシステム１８０への要求の場合は（ステップＡ４のＹｅｓ）、ステータスレジスタ１３２を１（ファイルシステムのリードライト要求受信）にする（ステップＡ５）。

【００５８】パケットからファイルシステム要求を取り出し、ファイル要求バッファ１３３に格納する。その要求は、ファイル操作、ファイル名、オフセット、データ長等からなる。さらに、要求がリードの場合は、ネットワークカード１３０上の送信バッファ１３４を確保して、そのアドレスをファイル要求バッファ１３３のデータアドレスに格納する。ライト要求の場合は、書き込むべきデータを格納したネットワークカード１３０上の受信バッファ１３５のアドレスをファイル要求バッファ１３３のデータアドレスに格納する（ステップＡ６）。

【００５９】その後、プロセッサへ割り込みをかける（ステップＡ７）。

【００６０】リモートファイルシステム１８０への要求でない場合、即ち、リード、ライト処理以外のファイルシステム要求の場合は（ステップＡ４のＮｏ）、通常のパケットとして、ネットワークカードドライバ１７０があらかじめ確保した主記憶１２０上の受信バッファ１３５へパケットを転送する。ステータスレジスタを２（通常パケット受信）にして（ステップＡ８）、プロセッサへ割り込みをかける（ステップＡ７）。

【００６１】データ転送が多い処理の場合は、本発明で提案する方法でデータをネットワークカード１３０、ディスクコントローラ１４０の間で直接やりとりする。本実施例の説明では、リード、ライト要求のみを扱っているが、その他にもデータ転送量が大きい要求があれば、同様に処理を行う。

【００６２】次に、ネットワークカード１３０のＤＭＡ転送の処理動作を図４のフローチャートを参照して説明する。

【００６３】転送要求レジスタ１３１にセット（格納）されている送信元アドレスから送信先アドレスへＤＭＡ転送でデータを送る（ステップＢ１）。

【００６４】ステータスレジスタ１３２を３にする。３は、ＤＭＡ転送完了を示す（ステップＢ２）。

【００６５】プロセッサに割り込みをかける（ステップＢ３）。

【００６６】次に、ネットワークカード１３０の送信の処理動作を図５のフローチャートにより説明する。

【００６７】パケット解析部１３６０により、パケットが通常のパケット送信か否かを判定する（ステップＣ１）。

【００６８】通常のパケット送信の場合（ステップＣ１のＹｅｓ）、通常のパケット送信を実行する（ステップＣ２）。その後、ステータスレジスタ１３２を４にして（４は、通常のパケット送信処理を示す）（ステップＣ３）、プロセッサに割り込みをかける（ステップＣ４）。

【００６９】通常のパケット送信でない場合（ステップＣ１のＮｏ）、送信バッファのデータ１３４とファイル要求からクラインアント計算機２００への返答を作成する（ステップＣ５）。この作成したパケットについてパケット解析部１３６０によりプロトコル処理を行う（ステップＣ６）。パケットをネットワークに送信する（ステップＣ７）。

【００７０】ネットワークカードドライバ１７０は、サーバ計算機１００のプロセッサ１０１が実行する、ネットワークカード制御ソフトウェアである。その処理動作を図６のフローチャートにより説明する。

【００７１】プロセッサが割り込みを受け、ネットワークカードドライバ１７０の割り込み処理ルーチンが呼び出される。

【００７２】ネットワークカードドライバ割り込み処理ルーチンは、リモートファイルシステム１８０への要求か、通常のパケットかを、ネットワークカード１３０のステータスレジスタを調べることで判定する（ステップＤ１）。

【００７３】リモートファイルシステム１８０への要求ではない場合、即ち、ステータスレジスタ１３２に格納された値が１以外の場合は（ステップＤ１のＮｏ）、ネットワークカードドライバ１７０の割り込み処理ルーチンは、通常のネットワークカードドライバ１７０と同様の動作をする。

【００７４】ここで、ステータスレジスタ１３２が２かどうかを判定する（ステップＤ４）。

【００７５】ステータスレジスタ１３２に格納された値が２の場合（ステップＤ４のＹｅｓ）、ネットワークカードドライバ１７０の割り込み処理ルーチンは、ネットワークカード１３０が転送したパケットのデータのうち、上位のプロトコル処理に不要なヘッダ（イーサネットフレーム情報）等を取り除き、プロトコルドライバ（ＴＣＰ／ＩＰ等）に渡す（ステップＤ５）。以降は、通常のパケット受信と同じ処理になるので、ここでは説明を省略する。

【００７６】リモートファイルシステム１８０への要求の場合、即ち、ステータスレジスタ１３２に格納された値が１の場合は（ステップＤ１のＹｅｓ）、ネットワー

クカードドライバ１７０の割り込み処理ルーチンは、ネットワークカード１３０のファイル要求バッファ１３３から、ファイル要求を取り出す（ステップＤ２）。

【００７７】このリモートファイルシステム要求を処理するワーカースレッド１８１を起動し、要求を渡す（ステップＤ３）。

【００７８】ステータスレジスタ１３２に格納された値が２以外の場合（但し、１は、既に除外されている）（ステップＤ４のＮｏ）、ステータスレジスタ１３２の値が３かどうかを判定する（ステップＤ６）。

【００７９】ステータスレジスタ１３２の値が３の場合（ステップＤ６のＹｅｓ）、ＤＭＡ転送を要求しているスレッドを起動する（ステップＤ７）。

【００８０】ステータスレジスタ１３２の値が３以外の場合（但し、１と２は既に除外されている）（ステップＤ６のＮｏ）、ステータスレジスタ１３２の値が４かどうかを判定する（ステップＤ８）。

【００８１】ステータスレジスタ１３２の値が４以外の場合（但し、１と２と３は既に除外されている）（ステップＤ８のＮｏ）、処理は終了する。

【００８２】ステータスレジスタ１３２の値が４の場合（ステップＤ８のＹｅｓ）、通常のパケット送信完了処理を実行する（ステップＤ９）。

【００８３】上記、図６のフローチャートの処理動作により、ネットワークカードドライバ１７０の割り込み処理はこれで完了し、以降、プロセッサが実行するワーカースレッド１８１（リモートファイルシステム処理を行う）が、次に説明する一連の処理動作を実行する。

【００８４】この処理動作を図７のフローチャートを参照して説明する。

【００８５】ワーカースレッド１８１は、渡されたファイル操作が、リードか、ライトか、その他の操作か、によって以下の処理を行う。

【００８６】まず、ワーカースレッド１８１は、渡されたファイル操作が、リード要求か否かを判定する（ステップＥ１）。

【００８７】リード要求の場合（ステップＥ１のＹｅｓ）、ワーカースレッド１８１は、ファイル要求のファイル、オフセット、データ長から、リードしたい部分が主記憶１２０上のバッファキャッシュ１２１に存在するかどうかを、ローカルファイルシステム１６０の機能を使って調べる（ステップＥ２）。

【００８８】バッファが存在する場合（ステップＥ２のＹｅｓ）は、該当するバッファのアドレスを得ることができる。

【００８９】バッファキャッシュ１２１に存在する場合は、以下の処理を行う。

【００９０】該当するバッファをロックする操作を、ローカルファイルシステム１６０の機能を用いて行う（ステップＥ３）。この操作により、そのバッファに対する新たな操作要求が来た場合には、その要求の処理を遅延する排他を行ったことになる。

【００９１】ワーカースレッド１８１は、転送要求レジスタ１３１にリードしたいバッファキャッシュ１２１上のデータのアドレスと、このデータを格納するネットワークカード１３０の送信バッファ１３４上のアドレスをセット（格納）し、この格納されたアドレスに基づき、バッファキャッシュ１２１のバッファの内容をネットワークカード１３０へＤＭＡ転送する要求を、ネットワークカード１３０のリモートファイル処理手段１３６に出し、その完了を待つ（ステップＥ４）。

【００９２】ネットワークカード１３０のリモートファイル処理手段は、上記ＤＭＡ要求を受けて、ネットワークカード１３０上の送信バッファ１３４にバッファを用意し、渡された主記憶１２０上のバッファのアドレスが指すデータをＤＭＡ転送する（ステップＥ５）。

【００９３】ネットワークカード１３０のリモートファイル処理手段１３６は、ＤＭＡ転送が終了すると、ステータスレジスタ１３２を３（ＤＭＡ転送完了）にして、プロセッサに割り込みをかける（ステップＥ６）。

【００９４】ネットワークカードドライバ１７０の割り込みルーチンが呼び出される。割り込みルーチンは、ＤＭＡ転送完了の割り込みであることをステータスレジスタ１３２を読むことで認識する。ステップＥ５の処理で待っているワーカースレッド１８１を起動し、割り込み処理を終了する（ステップＥ７）。

【００９５】ワーカースレッド１８１は、パケット送信要求をネットワークカード１３０のリモートファイル処理手段１３６に出す（ステップＥ８）。

【００９６】リモートファイルシステム要求（リード要求）に対してのデータが、（２－３）の転送でネットワークカード１３０上の送信バッファに入っているので、後は、送信を実行すればよい。

【００９７】ネットワークカード１３０のリモートファイル処理手段１３６は、送信バッファ１３４のデータを送信元（リード要求を出したクライアント計算機２００）に送り返すためにイーサネットパケットのヘッダを作成し、送信を実行する（ステップＥ９）。

【００９８】ワーカースレッド１８１は、ローカルファイルシステム１６０の機能を用いて、主記憶１２０のバッファキャッシュ１２１のバッファへのロックを解除する（ステップＥ１０）。以後、該当するバッファへの操作を他のスレッド、プロセス等が行うことができる。

【００９９】バッファに存在しない場合は、以下の操作を行う（ステップＥ２のＮｏ）。

【０１００】ワーカースレッド１８１は、ローカルファイルシステム１６０の機能を用いて、ファイルの読み出し操作で必要となるディスクブロックを調べる。ファイル名、オフセットの情報から、ディスク上のどの部分に要求されるデータが存在するかを調べる。ディスク１０

４上の位置は、通常ディスクブロック番号等で管理されているので、ここではディスクブロック番号を得る（ステップＥ１１）。

【０１０１】ワーカースレッド１８１は、ステップＥ１１で得たディスクブロックを読み出し、ネットワークカードドライバ１７０の割り込みルーチンから渡されたネットワークカード１３０上の送信バッファ１３４にＤＭＡ転送を行うために、ディスクドライバ１５０を呼び出す（ステップＥ１２）。

【０１０２】ディスクドライバ１５０は、その要求をディスクコントローラ１４０に伝え、完了を待つ（ステップＥ１３）。

【０１０３】ディスクコントローラ１４０のディスク要求処理手段は、データをいったんディスク１０４から読み出し、そのデータをディスクキャッシュ１４１に格納する。そのキャッシュデータをステップＥ１２で指示されたネットワークカード１３０の送信バッファ１３４に転送する（ステップＥ１４）。

【０１０４】ディスクコントローラ１４０のディスク要求処理手段１４２は、プロセッサ１０１に割り込みをかける（ステップＥ１５）。

【０１０５】ディスクドライバ１５０の割り込みルーチンは、ステップＥ１３で、その完了を待っているワーカースレッド１８１を起動し、割り込み処理を終了する（ステップＥ１６）。

【０１０６】ワーカースレッド１８１は、データ送信要求をネットワークカード１３０に出す（ステップＥ１７）。

【０１０７】これは、クライアント計算機２００から要求されたリモートファイルシステム要求（リード要求）のデータがネットワークカード１３０上に整ったので、ネットワークカード１３０に送信を指示することができるようになったからである。

【０１０８】ネットワークカード１３０のリモートファイル処理手段１３６は、送信バッファ１３４に入っているデータを使用して、リモートファイルシステム要求の返答を作成し、クライアント計算機２００に送信する（ステップＥ１８）。

【０１０９】ワーカースレッド１８１は、ローカルファイルシステム１６０の機能を用いて、ファイルの読み出し操作を出し、その完了を待つ（ステップＥ１９）。

【０１１０】このファイル読み出し要求を処理する必要は、本来はない。なぜなら、クライアント計算機２００から要求されたリード要求はすでに処理しているからである。しかし、ディスクから読み出したデータをサーバ計算機１００のバッファキャッシュ１２１に格納しておき、次のアクセスがあった場合に、再利用できるようにしておくことで、キャッシュ効果が期待できるためにバッファキャッシュ１２１にデータを格納しておいてもよい。

【０１１１】その後、ワーカースレッド１８１の処理を終了する。

【０１１２】リード要求で無い場合（ステップＥ１のＮｏ）、即ちライト要求の場合、ライト要求がライトスルー要求か否かを判定する（ステップＥ２０）。

【０１１３】ライトスルー要求の場合（ステップＥ２０のＹｅｓ）、即ちディスクに即座にデータを書き込む要求の場合は、以下のような処理を行う。

【０１１４】ワーカースレッド１８１は、ファイル要求のファイル、オフセット、データ長から、ライトすべき部分が主記憶上のバッファキャッシュ１２１に存在するかどうかをローカルファイルシステム１６０の機能を呼び出し調べる（ステップＥ２１）。

【０１１５】ローカルファイルシステム１６０は、バッファが存在する場合（ステップＥ２１のＹｅｓ）、該当するバッファのアドレスを求め、ワーカースレッド１８１は、ローカルファイルシステム１６０の機能を用いて、そのバッファを破棄する（ステップＥ２２）。これは、これから処理するライト要求によってデータが上書きされるので、主記憶１２０上のデータは、ディスク１０４に書き戻す必要がないためである。

【０１１６】ワーカースレッド１８１は、ローカルファイルシステム１６０の機能を用いて、ディスクブロックを調べ、ファイル要求のファイル、オフセット、データ長から、ライトするべきディスクブロックを得る（ステップＥ２３）。

【０１１７】ワーカースレッド１８１は、ディスクドライバ１５０を用いて、ネットワークカード１３０の受信バッファ１３５上にあるデータをステップＥ２３で得たディスクブロックへ書き込むように、要求を出し、その完了を待つ（ステップＥ２４）。

【０１１８】ディスクコントローラ１４０のディスク要求処理手段１４２は、ディスク１０４の書き込みを終了すると、プロセッサ１０１に割り込みをかける（ステップＥ２５）。

【０１１９】ディスクドライバ１５０の割り込み処理ルーチンは、ステップＥ２４で完了を待っているワーカースレッド１８１を起こし、割り込み処理を終了する（ステップＥ２６）。

【０１２０】ワーカースレッド１８１は、処理が完了したので、リモートファイルシステム要求に対する返答をクライアント計算機２００に送信することを、ネットワークカード１３０に要求を出す（ステップＥ２７）。

【０１２１】ネットワークカード１３０のリモートファイル処理手段１３６は、リモートファイルシステム要求の完了をクライアント計算機２００に送信する（ステップＥ２８）。

【０１２２】ワーカースレッド１８１は、ライト処理の指定を検査する（ステップＥ２９）。

【０１２３】ライト処理がバッファキャッシュ１２１を

使用しないモードであれば（ステップＥ２９のＮｏ）、処理を終了する。

【０１２４】ライト処理がバッファを使用するモードの場合（ステップＥ２９のＹｅｓ）、バッファキャッシュ１２１にデータを入れておくために、ワーカスレッド１８１は、ローカルファイルシステム１６０の機能を用いて、リード要求を処理し、その完了を待つ（ステップＥ３０）。

【０１２５】このリード要求も本来は実行しなくてもよいものである。リモートファイルシステム要求を処理する場合、バッファキャッシュ１２１を使用する、しないは通常は、クライアント計算機２００において意味があるものであるからである。

【０１２６】従って、ステップＥ３０はなくてもよい。

【０１２７】その後、ワーカースレッド１８１の処理を終了する。

【０１２８】ライト要求がライトスルーでない場合（ステップＥ２０のＮｏ）、以下の処理を行う。

【０１２９】ワーカースレッド１８１は、ローカルファイルシステム１６０の機能を用い、ファイル要求のファイル、オフセット、データ長から、ライトすべき部分が主記憶上のバッファキャッシュ１２１に存在するかどうかを判定する（ステップＥ３１）。

【０１３０】バッファが存在する場合（ステップＥ３１のＹｅｓ）、該当するバッファのアドレスを得ることができる。バッファが存在する場合は、以下の処理を行う。

【０１３１】ワーカースレッド１８１は、ステップＥ３１で得たバッファをロックする処理をローカルファイルシステム１６０の機能を用いて行う（ステップＥ３２）。

【０１３２】ワーカースレッド１８１は、受信バッファ１３５にあるデータのアドレスと、バッファキャッシュ１２１上のアドレスを転送要求レジスタ１３１にセットし、このアドレスに基づき、ネットワークカード１３０上の受信バッファ１３５にあるデータをステップＥ３１で得たバッファキャッシュ１２１上のアドレスへＤＭＡ転送するように、ネットワークカード１３０のリモートファイル処理手段１３６に要求を出し、その完了を待つ（ステップＥ３３）。

【０１３３】この転送により、バッファキャッシュ１２１上のデータを、リモートファイル要求（ライト要求）のデータに置き換えることになる。

【０１３４】ネットワークカード１３０のリモートファイル処理手段１３６は、ＤＭＡ転送を完了したら、ステータスレジスタを３にセットして、プロセッサ１０１に割り込みをかける（ステップＥ３４）。

【０１３５】ネットワークカードドライバ１７０の割り込みルーチンは、ステップＥ３３で待つワーカースレッド１８１を起こし、割り込みを完了する（ステップＥ３５）。

【０１３６】ワーカースレッドは１８１、ロックしたバッファキャッシュ１２１上のバッファのロックを解除する（ステップＥ３６）。

【０１３７】その後、ワーカースレッド１８１の処理を終了する。

【０１３８】バッファがない場合（ステップＥ３１のＮｏ）、以下の処理を行う。

【０１３９】ワーカースレッド１８１は、ローカルファイルシステム１６０の機能を用いて、バッファキャッシュ１２１上にバッファを確保し（ステップＥ３７）、そのバッファをロックする（ステップＥ３２）。

【０１４０】ステップＥ３２以降は、バッファがある場合と同様の処理を続ける。

【０１４１】以上の様に、従来は、ネットワークカード１３０とディスクの間のデータ転送は、主記憶１２０にいったんデータを蓄積して行わなければならなかった。しかし、本発明によれば、リモートファイルシステム要求をネットワークカード１３０、ネットワークカードドライバ１７０、ディスクドライバ１５０とファイルシステムが協調して処理することで、ネットワークカード１３０とディスクコントローラ１４０の間で直接データをやりとりできる。また、そのデータのやりとりを主記憶１２０上のファイルシステムのバッファとの一貫性を保ちながら行っているので、サーバ計算機１００上のローカルファイルシステム１６０がディスク１０４上のデータを操作する機能を維持している。

【０１４２】

【発明の効果】以上詳記したように本発明によれば、ネットワークカード、ディスクコントローラにあって、リモートファイル操作を処理するので、サーバ計算機のプロセッサは、リモートファイル操作を処理するためのプロトコル処理やファイル処理等を実行することがなくなり、それ以外の処理に資源、時間を割り当てることができる。

【０１４３】例えば、従来技術では、ライト処理の場合、ネットワークカードからデータを主記憶に転送し、更に主記憶からディスクへデータを転送するために、システムバス上に同一のデータが２回流れるものであったが、本発明によれば、ネットワークカードからディスクへＩ／Ｏバスのみを用いてデータを転送するので、システムバスを用いるデータの転送が必要ない。

【図面の簡単な説明】

【図１】本発明の一実施の形態に係わるネットワークファイルサーバシステムの構成を示すブロック図。

【図２】同実施の形態に係わるファイル要求バッファのデータ構成を示す図。

【図３】同実施の形態のネットワークカードの受信の際の処理動作を示すフローチャート。

【図４】同実施の形態に係わるネットワークカードのＤ

ＭＡ転送の際の処理動作を示すフローチャート。
【図５】同実施の形態に係わり、ネットワークカードの送信の際の処理動作を示すフローチャート。
【図６】同実施の形態に係わり、ネットワークカードドライバの割り込み処理ルーチンの処理動作を示すフローチャート。
【図７】同実施の形態に係わり、ワーカスレッドの処理動作を示すフローチャート。
【図８】従来のネットワークファイルサーバシステムの構成を示す図。
【符号の説明】
１０…サーバ計算機
１１…プロセッサ
１２…システムバス
１３…ＰＣＩバス
１４…主記憶
１５…バッファキャッシュ
１６…ディスクコントローラ
１７…ディスク
１８…ネットワークカード
１９…受信バッファ
２０…ネットワークドライバ
２１…プロトコルスタック
２２…リモートファイルシステム
２３…ローカルファイルシステム
２４…ネットワーク
２５…クライアント計算機
１００…サーバ計算機
１０１…プロセッサ
１０２…システムバス
１０３…Ｉ／Ｏバス
１０４…ディスク
１２０…主記憶
１２１…バッファキャシュ
１２２…送信バッファ
１２３…受信バッファ
１３０…ネットワークカード
１３１…転送要求レジスタ
１３２…ステータスレジスタ
１３３…ファイル要求バッファ
１３３０…リモートファイル要求
１３３１…ファイル名
１３３２…オフセット
１３３３…データ長
１３３４…データアドレス
１３４…送信バッファ
１３５…受信バッファ、
１３６…リモートファイル処理手段
１３６０…パケット解析部
１４０…ディスクコントローラ
１４１…ディスクキャシュ
１４２…ディスク要求処理手段
１５０…ディスクドライバ
１６０…ローカルファイルシステム
１６１…ロック機能
１６２…アンロック機能
１７０…ネットワークカードドライバ
１８０…リモートファイルシステム
１８１…ワーカスレッド
２００…クライアント計算機
３００…ネットワーク
１３３０…リモートファイル要求

【図２】

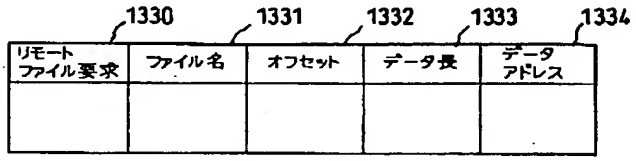

ファイル要求バッファ

【図４】

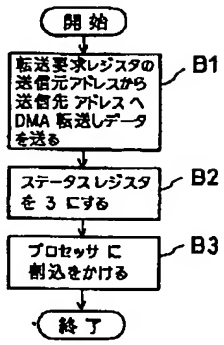

【図１】

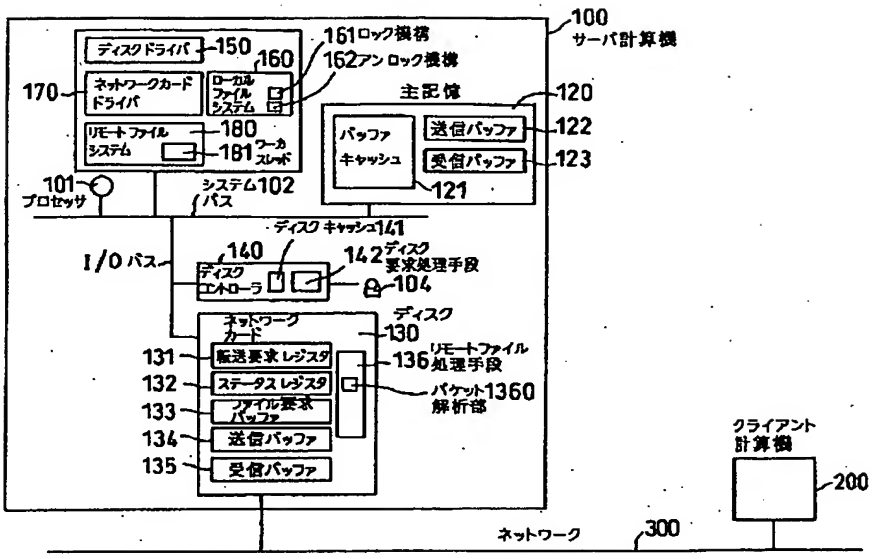
100
サーバ計算機
ディスクドライバ
150
161ロック機構
160
162アンロック機構
ネットワークカードドライバ
170
ローカルファイルシステム
主記憶
120
リモートファイルシステム
180
181ワーカスレッド
バッファキャッシュ
送信バッファ
122
受信バッファ
123
121
101
プロセッサ
システムバス
102
ディスクキャッシュ141
I/Oバス
140
ディスクコントローラ
142ディスク要求処理手段
104
ネットワークカード
ディスク
130
131
転送要求レジスタ
136リモートファイル処理手段
132
ステータスレジスタ
133
ファイル要求バッファ
1360パケット解析部
134
送信バッファ
135
受信バッファ
クライアント計算機
200
ネットワーク
300

【図３】

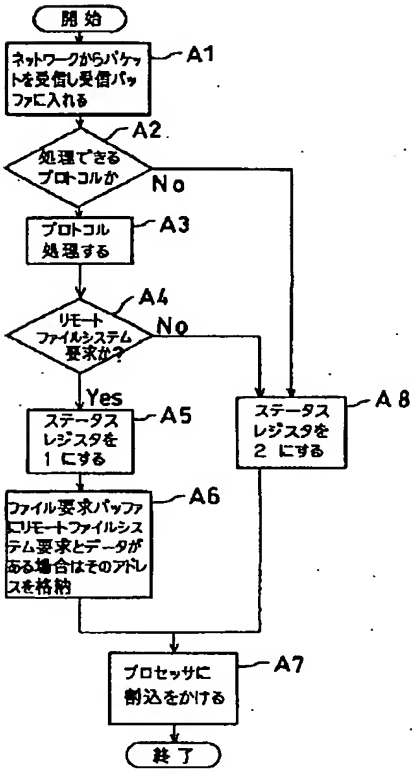
開始
ネットワークからパケットを受信し受信バッファに入れる
A1
処理できるプロトコルか
A2
No
プロトコル処理する
A3
リモートファイルシステム要求か?
A4
No
Yes
ステータスレジスタを1にする
A5
ステータスレジスタを2にする
A8
ファイル要求バッファにリモートファイルシステム要求とデータがある場合はそのアドレスを格納
A6
プロセッサに割込をかける
A7
終了

【図５】

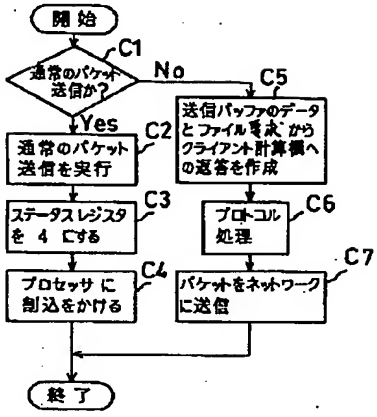
開始
通常のパケット送信か?
C1
No
C5
送信バッファのデータとファイル要求からクライアント計算機への返答を作成
Yes
通常のパケット送信を実行
C2
ステータスレジスタを4にする
C3
プロトコル処理
C6
プロセッサに割込をかける
C4
パケットをネットワークに送信
C7
終了

【図６】

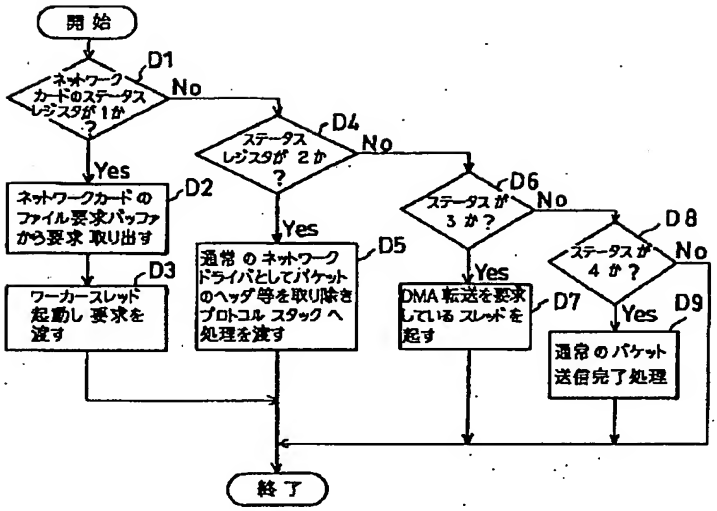
開始
D1
ネットワークカードのステータスレジスタが1か？
No
Yes
D2
ネットワークカードのファイル要求バッファから要求取り出す
D3
ワーカースレッド起動し要求を渡す
D4
ステータスレジスタが2か？
No
Yes
D5
通常のネットワークドライバとしてパケットのヘッダ等を取り除きプロトコルスタックへ処理を渡す
D6
ステータスが3か？
No
Yes
D7
DMA転送を要求しているスレッドを起す
D8
ステータスが4か？
No
Yes
D9
通常のパケット送信完了処理
終了

【図８】

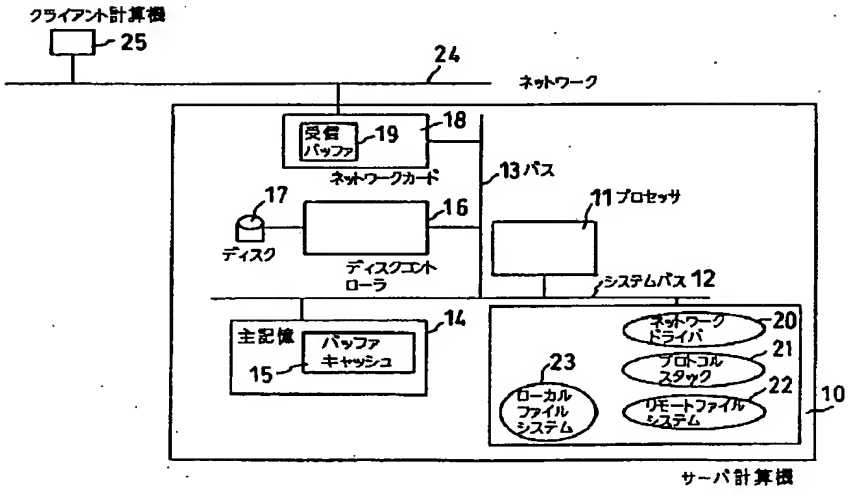
クライアント計算機
25
24
ネットワーク
受信バッファ
19
18
ネットワークカード
13 バス
17
ディスク
16
ディスクコントローラ
11 プロセッサ
システムバス 12
主記憶
バッファキャッシュ
15
14
ネットワークドライバ
20
プロトコルスタック
21
ローカルファイルシステム
23
リモートファイルシステム
22
10
サーバ計算機

【図７】

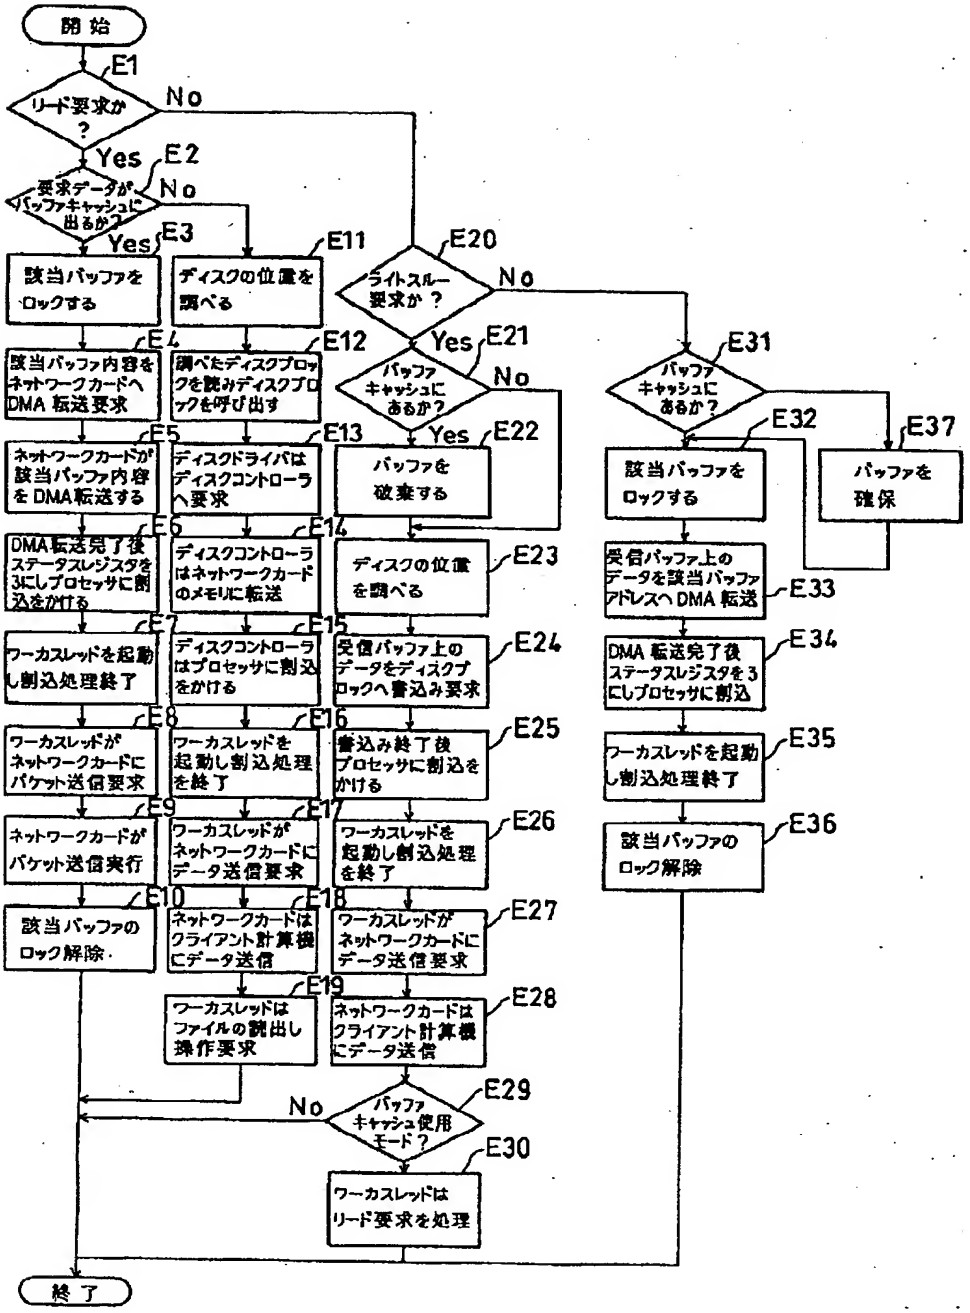
開始
E1
リード要求か？
No
Yes
E2
要求データがバッファキャッシュに出るか？
No
Yes
E3
該当バッファをロックする
E4
該当バッファ内容をネットワークカードへDMA転送要求
E5
ネットワークカードが該当バッファ内容をDMA転送する
E6
DMA転送完了後ステータスレジスタを3にしプロセッサに割込をかける
E7
ワーカスレッドを起動し割込処理終了
E8
ワーカスレッドがネットワークカードにパケット送信要求
E9
ネットワークカードがパケット送信実行
E10
該当バッファのロック解除
E11
ディスクの位置を調べる
E12
調べたディスクブロックを読みディスクブロックを呼び出す
E13
ディスクドライバはディスクコントローラへ要求
E14
ディスクコントローラはネットワークカードのメモリに転送
E15
ディスクコントローラはプロセッサに割込をかける
E16
ワーカスレッドを起動し割込処理を終了
E17
ワーカスレッドがネットワークカードにデータ送信要求
E18
ネットワークカードはクライアント計算機にデータ送信
E19
ワーカスレッドはファイルの読出し操作要求
E20
ライトスルー要求か？
No
Yes
E21
バッファキャッシュにあるか？
No
Yes
E22
バッファを破棄する
E23
ディスクの位置を調べる
E24
受信バッファ上のデータをディスクブロックへ書込み要求
E25
書込み終了後プロセッサに割込をかける
E26
ワーカスレッドを起動し割込処理を終了
E27
ワーカスレッドがネットワークカードにデータ送信要求
E28
ネットワークカードはクライアント計算機にデータ送信
E29
バッファキャッシュ使用モード？
No
E30
ワーカスレッドはリード要求を処理
E31
バッファキャッシュにあるか？
E32
該当バッファをロックする
E33
受信バッファ上のデータを該当バッファアドレスへDMA転送
E34
DMA転送完了後ステータスレジスタを3にしプロセッサに割込
E35
ワーカスレッドを起動し割込処理終了
E36
該当バッファのロック解除
E37
バッファを確保
終了

PATENT ABSTRACTS OF JAPAN

(11)Publication number : 06-332782
(43)Date of publication of application : 02.12.1994

(51)Int.Cl. G06F 12/00
G06F 15/16
G06F 15/16

(21)Application number : 06-050126
(22)Date of filing : 22.03.1994

(71)Applicant : HITACHI LTD
HITACHI COMPUT ENG CORP LTD

(72)Inventor : AKISAWA MITSURU
YAMASHITA YOJI
TADA KATSUMI
KAWAGUCHI HISAMITSU
KATO KANJI
KITO AKIRA
YAMADA HIDENORI

(30)Priority
Priority number : 05 61602 Priority date : 22.03.1993 Priority country : JP

(54) FILE SERVER SYSTEM AND FILE ACCESS CONTROLLING METHOD THEREFOR

(57)Abstract:
PURPOSE: To prevent the throughput due to the centralization of access requests in a specified file server from plural clients, in a file server system where plural file servers accessing each file storage devices are arranged side by side via a network.
CONSTITUTION: The master file server 100 of file servers 100, 110, 120 and 130 composing a file server system 90 is provided with a file control means controlling files by using a load information table 508 measuring/controlling the load status of each file server and a file attribute table recording/controlling a file server in charge of the access every file block, selecting a file server where load is light at the time of writing a file, in particular and distributing the file access requests transmitted from client computers 10, 20 and 30 to the selected file server.

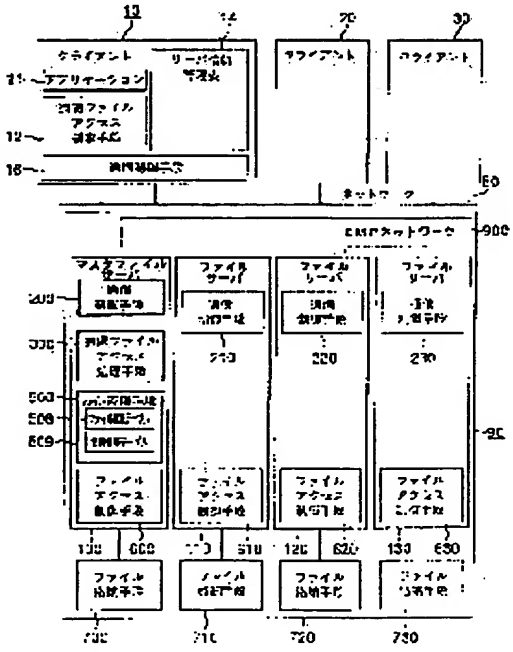

LEGAL STATUS

[Date of request for examination] 14.03.2001

[Date of sending the examiner's decision of rejection]

[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]

[Date of final disposal for application]

[Patent number]

[Date of registration]

[Number of appeal against examiner's decision of

rejection]
[Date of requesting appeal against examiner's decision of rejection]
[Date of extinction of right]

* NOTICES *

1. This document has been translated by computer.So the translation may not reflect the original precisely.
2. **** shows the word which can not be translated.
3.In the drawings, any words are not translated.

CLAIMS

[Claim(s)]
[Claim 1] In the file server system which shares the file which has two or more file servers **** (ed) on the network, and was distributed by the above-mentioned file server among two or more client computers A file storing means to store a file in each of two or more above-mentioned file servers, The first communications control means which performs communications control with other file servers through the above-mentioned network, A file access control means to receive a file access demand and to perform a file access to the above-mentioned file storing means is established. The second communications control means which performs communications control with the above-mentioned client computer to a specific file server among two or more above-mentioned file servers, A remote file-access-operation means to manage the communications protocol of the file access demand published from the above-mentioned client computer, A load information monitoring means to measure each load situation of two or more above-mentioned file servers, The file server which performs a file access from two or more above-mentioned file servers with reference to the load situation measured by the above-mentioned load information monitoring means is selected. When the selected file server is a self file server, a file access demand is published to the file access control means of a self file server. When the selected file servers are other file servers, the communications control means of the above 1st is minded. The file server system characterized by establishing further a file access demand distribution means to publish the file access demand which publishes a file access demand to the file access control means of the selected file server.
[Claim 2] The above-mentioned load information monitoring means is a file server system including the means which carries out counting of the unsettled number of file access demands in each of two or more above-mentioned file servers according to claim 1.
[Claim 3] The file server system according to claim 1 characterized by providing the following. The above-mentioned file access demand distribution means is a write-in read-out judging means for the file access demand published from the above-mentioned client computer to read in a write request, and to judge a demand. A file division arrangement means to select the file server which stores a file with reference to the load situation measured by the aforementioned load information monitoring means at the time of file writing. A file server scheduling means for access to select the file server made into the object of read-out from the file server in which it reads with reference to the load situation measured by the above-mentioned load information monitoring means at the time of file read-out, and the object file is stored.
[Claim 4] The above-mentioned file division arrangement means is a file server system according to claim 3 characterized by establishing a file division arrangement means to select at least two or more file servers which store the file for writing.
[Claim 5] It is the file-server system according to claim 3 characterized by for the above-mentioned file division arrangement means to select at least two or more file servers which store the file for writing, and for the above-mentioned file-server scheduling means for access to read a file server with a light load with reference to the load situation acquired by the aforementioned load information monitoring means among the file servers in which the file for read-out is stored, and to select as a target file server.

[Claim 6] It is the file server system according to claim 3 which the above-mentioned file division arrangement means generates the file attribute table showing the correspondence relation between this file and this file server in case the file server which stores a file is selected, and is carried out as the feature here where the file server in which the above-mentioned server scheduling means for access is read with reference to the above-mentioned file attribute table, and the target file is stored is specified.
[Claim 7] The file server system according to claim 1 characterized by preparing the communications control means of the above second, and the above-mentioned remote file-access-operation means or more in at least two of two or more above-mentioned file servers, respectively.
[Claim 8] The file server system according to claim 1 characterized by preparing the above-mentioned load information monitoring means and the above-mentioned file access demand distribution means or more in at least two of two or more above-mentioned file servers, respectively.
[Claim 9] The file server system according to claim 7 characterized by preparing the above-mentioned load information monitoring means and the above-mentioned file access demand distribution means or more in at least two of two or more above-mentioned file servers, respectively.
[Claim 10] It is the file server system according to claim 1 which the above-mentioned client computer is connected to the above-mentioned network, and is characterized by ** to which the communications control means of the above first achieves the function of the communications control of the above-mentioned client computer and the above-mentioned specific file server instead of the communications control means of the above second.
[Claim 11] It is the file server system according to claim 1 characterized by connecting the above-mentioned client computer to the 1st network, connecting two or more above-mentioned file servers to the 2nd network, and connecting the above 1st and the 2nd network with a bridge means to distribute the file access demand from the above-mentioned client computer to the above-mentioned specific file server.
[Claim 12] The communications control means of the above first is a file server system according to claim 1 characterized by performing communication with other file servers through a system bus.
[Claim 13] The above-mentioned system bus is a file server system according to claim 12 characterized by being the dedicated bus used only for communication between two or more above-mentioned file servers.
[Claim 14] In the file access control method in the file server system which shares the file which has two or more file servers ****(ed) on the network, and was distributed by two or more file servers of the above-mentioned file among two or more client computers The file access demand which measured each load information on two or more above-mentioned file servers, and was published through the above-mentioned network from the client computer in the **** case with a receptacle The file access control method containing the step of selecting the file server which performs a file access with reference to the above-mentioned load information, and distributing a file access demand to the above-mentioned selection file server.
[Claim 15] The step which measures the above-mentioned load information is the file access control method containing the step which carries out counting of each unsettled number of file access demands of two or more above-mentioned file servers according to claim 14.
[Claim 16] The step which selects the file server which performs the above-mentioned file access The file access demand published from the client computer reads in a write request, and judges a demand. At the time of file writing, the file server for file storing is selected with reference to the measured load situation. The file access control method according to claim 14 characterized by including the step of reading from the file server in which it reads with reference to the measured load situation at the time of file read-out, and the object file is stored, and selecting the target file server.
[Claim 17] The file access control method characterized by selecting at least two or more file servers which write in in the file access control method according to claim 16 at the step which

selects the file server for [above] file storing, and store an object file.
[Claim 18] The file access control method characterized by choosing and reading a file server with a light load based on the load information measured among two or more file servers in which it reads in the file access control method according to claim 16 at the step which selects the file server for [above] read-out, and the object file is stored, and considering as the target file server.
[Claim 19] In the file access control method according to claim 16, in case the file server which stores a file is selected, the file attribute table showing the correspondence relation between this file and this file server is generated, and the above-mentioned server scheduling means for access specifies the file server in which it reads with reference to the above-mentioned file attribute table, and the target file is stored. [Claim 20] In the file access control method according to claim 14, the step which selects the above-mentioned file server for a file access The load information on each file server is measured by at least two or more file servers. The file access demand published from the client computer is received by the file server which measures the above-mentioned load information. The high-speed file access control method characterized by distributing a file access demand to the file server which selected the file server for a file access with reference to the above-mentioned load information, and was selected as a file server for a file access.
[Claim 21] The file access control method characterized by writing in a file server with few loads, selecting as an object file server when a file access is file writing, reading a file server with few loads from the file server in which the file is stored when a file access is file read-out in the file access control method according to claim 20 at the step which selects the above-mentioned file server for a file access, and selecting as an object file server.

[Translation done.]

* NOTICES *

DETAILED DESCRIPTION

[Detailed Description of the Invention]
[0001]
[Industrial Application] this invention is concerned with computing systems, such as a workstation and a server, and relates to the file server system especially in the computing system of multiprocessor composition which accesses the file stored in the secondary storage at high speed, and its file access control method.
[0002]
[Description of the Prior Art] In recent years, the network of a computer has been progressing. In connection with this, the need of the file server which manages collectively the file shared between computers is increasing. This is because a file system can be built by the low cost. That is, it is because two or more same files are copied and it is necessary to cease to possess them among two or more computers, since it becomes sharable [a file] among two or more computers by using a file server. It becomes possible to access as if it was the file stored in the client computer itself by usually carrying the network correspondence file system in the file server, and carrying a network correspondence file system access program also in the computer of a client side connected to the same network. Therefore, it becomes possible to access to the file which is accumulated on a file server from every client computer connected to the network, and is managed, and sharing of the file between two or more client computers is realized.
[0003] Managing NFS and NIS (Hal Stern, O'Reilly & Associates, Inc, June 1991, p.113 to p.159) has the description about a network correspondence file system.
[0004] However, when sharing the file in a file server using a network correspondence file system, a performance problem may arise. That is, in performing a file access simultaneously from many client computers, a load concentrates on a file server and the situation that an access result is not obtained immediately occurs.
[0005] Therefore, when the load to a file server becomes excessive and the access throughput of a client computer falls, ****(ing) two or more sets of file servers on a network, and distributing the access demand from two or more client computer is performed. Each client computer manages the information on all the file servers currently installed on the network, and publishes an access demand to the file server in which the file for access exists with reference to this management information. When the file for access of each client computer is stored in the separate file server by this, it becomes possible to distribute a load and it can improve an access throughput.
[0006] Although it is not client - and - server composition, one main processor manages two or more whole data files, and the above-mentioned system and a similar system are indicated by Japanese public presentation JP,04,B -48352 [No. (1992)] in respect of if these data files are distributed by two or more sub processors.
[0007]
[Problem(s) to be Solved by the Invention] Though two or more sets of file servers are installed and a file is shared among many client computers as mentioned above, the following problems remain.
[0008] Two or more client computers may give an access demand to one file server

simultaneously, an applicable file server serves as a bottleneck in that case, and the problem that a throughput will fall produces a client computer in order to access the file server in which a file exists completely regardless of the load situation of a file server. The degradation will become excessive if two or more directories where a client computer is the same and same files are accessed especially simultaneously. Even if this problem increases the installation number of the character top file server, it is not solvable.
[0009] The purpose of this invention is offering the file server system which can prevent generating of the bottleneck by concentration of access to a specific file server, and the fall of the throughput accompanying it, and its file access control method, even when two or more client computers access the same directory and the same file simultaneously in the network which ****(ed) two or more file servers, in order to share the file between many client computers.
[0010]
[Means for Solving the Problem] One feature of the file access control method of this invention In the file server system which shares the file which has two or more file servers ****(ed) on the network, and was distributed by two or more file servers among two or more client computers The file access demand which measured each load information on two or more above-mentioned file servers, and was published through the above-mentioned network from the client computer in the **** case with a receptacle The file server which performs a file access with reference to the above-mentioned load information is selected, and it is in the file access control method containing the step of distributing a file access demand to the above-mentioned selection file server.
[0011] When the file access demand from a client computer being a write request of a new file, speaking more concretely, the load information on two or more file servers is measured, the lightest file server of a load is selected, and a file write request is published to the file server. Or in producing the file of mirror composition, two or more file servers with a light load are selected, and it publishes a file write request to each of those file servers. Moreover, the file access demand from a client computer is a file read-out demand, when the file for read-out is carried out to mirror composition, the load information on two or more file servers which take charge of two or more multiple-files enclosure of each in which the file for read-out was stored is measured, one lightest file server of a load is selected, and a file read-out demand is published to the file server.
[0012] Measurement of the above-mentioned load information is performed by carrying out counting of each unsettled number of file access demands of two or more above-mentioned file servers. For this reason, at least one of two or more file servers is made into a master file server, and the load information monitoring means which records and updates each unsettled number of file access demands of two or more file servers at a load information table is prepared in this master file server. Moreover, a means to distribute the file access demand from a client computer using the file attribute table which records the correspondence relation of the file server which took charge of the writing of each file and its file, and the above-mentioned load information table is prepared in this master file server.
[0013] The typical composition of the file server system according to this invention In the file server system which shares the file which has two or more file servers ****(ed) on the network, and was distributed by the above-mentioned file server among two or more client computers A file storing means to store a file in each of two or more above-mentioned file servers, The first communications control means which performs communications control with other file servers through the above-mentioned network, A file access control means to receive a file access demand and to perform a file access to the above-mentioned file storing means is established. On the other hand, to a specific file server among two or more above-mentioned file servers at these In addition, the second communications control means which performs communications control with the above-mentioned client computer, A remote file-access-operation means to manage the communications protocol of the file access demand published from the above-mentioned client computer, A load information monitoring means to measure each load situation of two or more above-mentioned file servers, The file server which performs a file access from

two or more above-mentioned file servers with reference to the load situation measured by the above-mentioned load information monitoring means is selected. When the selected file server is a self file server, a file access demand is published to the file access control means of a self file server. It is the composition of having established further a file access demand distribution means to publish a file access demand to the file access control means of the selected file server through the communications control means of the above 1st when the selected file servers were other file servers.

[0014]

[Function] According to such a method and a system configuration, it can access to a file server with few file access loads. And since a file and its duplicate file are stored in two or more file servers, the access demand from a client computer to the same directory and the same file can also be distributed according to the load situation to two or more file servers. That is, even when ****(ing) two or more file servers, sharing a file among many client computers on a network and two or more directories and files with the same client computer are accessed simultaneously, generating of the bottleneck by concentration of access to a specific file server and the fall of the throughput accompanying it can be prevented, and access of the high throughput from a client computer can be realized.

[0015]

[Example] The composition of the example of this invention is explained with reference to drawing 1 .

[0016] The file server system 90 constituted from a loose-coupling multiprocessor and the client computers 10, 20, and 30 are connected by Local Area Network 50. In each of the client computers 10, 20, and 30, if an application program 11 is performed and a file access demand occurs by this, a file access demand will be published from the remote file access demand generating means 12 in the file server system 90. Specifically, a file access demand is transmitted to the file server 100 which is specific one of four sets of the file servers 100, 110, 120, and 130 which constitute the file server system 90 through Local Area Network 50 from the communications control means 16. As for four sets of file servers 100, 110, 120, and 130, each takes charge of individually access of the file storing meanses 700, 710, 720, and 730. Therefore, the file access control meanses 600, 610, 620, and 630 are formed in file servers 100, 110, 120, and 130, respectively. Moreover, file servers 100, 110, 120, and 130 communicate mutually through the LCMP network 900. For this reason, the communications control meanses 200, 210, 220, and 230 are formed in each file server.

[0017] In this example, the above-mentioned specific file server 100 is called master file server. The remote file-access-operation means 300 for the master file server 100 receiving the file access demand further published from the client computer and a file management means 500 to distribute the file access demand which managed and received distribution of a file so that the load of each file server might not incline greatly to each file server are formed. For distribution of this file management and a file access demand, the file attribute load information table 508 and 509 is used. The information on the master file server 100, i.e., the machine address of the master file server 100, is stored in the server information management table 14 of a client computer.

[0018] Drawing 2 is the block diagram showing the equipment configuration of the master file server 100. The master file server 100 includes the processor 101 mutually connected by the system bus 107, main memory 102, the network interface circuit 103, and the LCMP network interface circuit 104. The remote file-access-operation program 301, file management 501, the file access control program 601, and a communication control program 201 are loaded to main memory 102 from the secondary storage which is not illustrated at the time of system starting, respectively, and the remote file-access-operation means 300 which this showed to drawing 1 , the file management means 500, the file access control means 600, and the communications control means 200 are formed. A file storing means 700 for the master file server 100 to write in and to take charge of read-out is a magnetic disk unit as shown in drawing 2 , and it is connected to a system bus 107. In addition, the file storing meanses 700 may be optical-magnetic disc equipment, an optical disk unit, and other secondary storages.

[0019] File servers 110, 120, and 130 other than master file server 100 of drawing 1 also have the composition almost same with being shown in drawing 2 , respectively. However, a remote file access program and file management are not loaded to such main memory. Moreover, the network interface circuit 103 for connection to Local Area Network 50 is also unnecessary.

[0020] Drawing 3 shows the program composition of the master file server 100. The network access program 205 which a communication control program 201 turns into to the interface of Local Area Network 50 and the master file server 100, The interprocessor communication drive-access program 206 used as the interface of the LCMP network 900 and the master file server 100, The network communication protocol control program 207 which carries out protocol conversion and which is passed so that the remote file-access-operation program 301 can interpret the demand received from the network access program 205, It consists of interprocessor communication protocol control programs 208 which carry out protocol conversion of the access demand to other file servers interpreted by the file access control program 601 explained later, and are passed to the interprocessor communication drive-access program 206. The file access control program 601 receives the information about file enclosure and a file server from file management 501. When the self processor 101 accesses the file enclosure 700 which takes charge of an access control, the information about file enclosure is passed to the file enclosure access program 604. When other file servers 110-130 access the file enclosure 710-730 which takes charge of an access control, the information about file enclosure is passed to the interprocessor communication protocol control program 208. The file enclosure discernment program 603 which requests access from other file servers, The information about file enclosure is received from the file enclosure discernment program 603, and it consists of file enclosure access programs 604 which access the magnetic disk unit 700 which stores the target file.

[0021] File management 501 is explained also with reference to drawing 4 which shows still more detailed program composition. File management 501 changes into the information on a file server, the information on file enclosure, and the information on the file storing position in file enclosure the file access demand which managed the file attribute table 508 and the load information table 509, and was passed from the remote file-access-operation program 301 using these, and passes it to the file access control program 601. File server selection for [according to distribution and it of a file] access is processed. Therefore, the file management 501 The file access demand receptionist program 504 which the file access demand passed from the remote file-access-operation program 301 is received, and it reads in a write request, and distinguishes a demand, The file distribution program 502 which determines by which file server a file is written in at the time of file writing, The read-out demand scheduling program 503 which determines which file server is accessed at the time of read-out, It consists of load information monitoring programs 505 which measure the load situation of each file server by carrying out counting of the number of unsettled access demands of each file server. The information on the file storing position in the file server identifier corresponding to each file by which the file is stored in the file attribute table 508, a file enclosure identifier, and file enclosure is held. The number of unsettled access demands of each file server is held at the load information table 509.

[0022] Next, the 1st example of a file attribute table is shown in drawing 5 . This example is an example in the case of performing distribution in a file unit, without having a duplicate, without dividing one file. A file attribute table consists of two fields, (1) file-attribute field and (2) disk-block index area. A file attribute field consists of each entry of a file size, file storing mode, a file access processor identifier, and a file storing device identifier. It is shown whether the file is stored in the file enclosure in which the file's being stored in the file enclosure to which the self file server which has managed a local, those with remote **, and the file attribute table takes charge of an access control in file storing mode, or other file servers take charge of an access control. A file access processor identifier shows the identifier of the file server which takes charge of the access control of file enclosure with which the file corresponding to a file attribute table is stored. A file storing device identifier shows the file enclosure in which the file is stored. The disk block index area consists of indexes which show the position within the file enclosure of each of a series of disk block which constitutes a file.

[0023] Next, the 2nd example of a file attribute table is shown in drawing 6 . This example is an example in the case of distributing by dividing one file. A file attribute table consists of two fields, (1) file-attribute field and (2) disk-block index area, like the 1st example of drawing 5 . However, the file attribute field existed for every disk block, and the storing place is specified. The example shown in drawing 6 shows that the 1st data block which constitutes a file exists in the position of the index of No. 100 of the disk unit of No. 1 where the 1st file server performs an access control. It is shown that the 3rd data block exists in the position of the index of No. 200 of the disk unit of No. 1 where, as for the 2nd data block, the 2nd file server performs an access control hereafter in the position of the index of No. 300 of the disk unit of No. 1 where the 3rd file server performs an access control.

[0024] On the other hand, the program composition of a file server 110 is as being shown in drawing 7 . A communication control program 211 consists of an interprocessor communication drive-access program 212 which becomes the interface of transmission through the LCMP network 900, i.e., an interface with the master file server 100, and an interprocessor communication protocol control program 213 which carries out protocol conversion and which is passed so that the file access control program 611 can interpret the access demand received from the interprocessor communication drive-access program 206. A file access control program interprets the access demand received from the interprocessor communication protocol control program 208, and consists of file enclosure access programs 612 which access the magnetic disk unit 710 which stores the target file. The program composition of file servers 120 and 130 is completely the same as that of drawing 7 .

[0025] Next, operation of this example is explained using drawing 8 .

[0026] If the processing demand which includes a file access demand or a file access by execution of an application program 11 occurs in either of the client computers 10, 20, and 30, the remote file access demand program 13 will be started, and a processing demand will be transmitted to the master file server 100 through Local Area Network 50. Communication through Local Area Network 50 is performed to a client computer and the master file server 100 using the communication control programs 17 and 201 carried, respectively. If a file access demand is sent to a file server 100, the remote file-access-operation program 301 of a file server 100 will be started. In the remote file-access-operation program 301, the received content is analyzed, the file access demand from a client computer is extracted, and a file-access-operation demand is sent to file management 501.

[0027] File management 501 operates, as shown in drawing 9 . first, if judge whether the file access demand is writing and whether it is read-out, write in, come out, and it is, and the file distribution program 502 is started and read, comes out and it is after receiving the file access demand from the remote file-access-operation program 301 in the file access demand receptionist program 504, it will read and the demand scheduling program 503 will be started In the file distribution program 502, the file attribute table to a write-in file is created, and, next, a file server with few access demand unsettled numbers is determined with reference to the load information table 509 as a file server which stores a file. Moreover, in creating the duplicate of a file and storing in other file servers, with reference to the load information table 509, it determines a file server with few access demand unsettled numbers again as a file server which stores the duplicate of a file. It records on the file attribute table 508 by making into a server identifier the information on the file server which stores these files and a duplicate file, and the load information monitoring program 505 is started. In the read-out demand scheduling program 503, the file attribute table 508 to the file to read is gained, and the file server in which the applicable file is stored is deduced from there. When the file is stored not only in one file server but in the file server of others [duplicate / the], it determines which shall be read between a file main part and a duplicate with reference to the load information table 509, and the load information monitoring program 505 is started. In the load information monitoring program 505, by incrementing the access demand unsettled number to the file server for access, the monitoring of the load information is carried out, the information which shows which portion of the target file is accessed is sent to the file access control program 601, and the file access control program 601 is started.

[0028] The file access control program 601 operates according to the processing flow steps 651, 652, and 653 shown in drawing 8 . It first judges whether the file enclosure discernment program 603 is access to the file enclosure 710-730 in which other file servers 110-130 take charge of an access control for whether it is access to the file enclosure 700 in which the information passed from file management 501 is analyzed, and the master file server 100 takes charge of an access control (Step 651). In being the former, the information about the file enclosure 700 is passed to the file enclosure access program 604 of the master file server 100, and it directs a file access. In response, the file enclosure access program 604 starts access to the file enclosure 700 (Step 652). In being the latter, it passes the information about file enclosure to the interprocessor communication protocol control program 208 in a communication control program 201, and the execution file server of a file access is specified, and a transfer of a demand is requested. The interprocessor communication protocol control program 208 is processed so that these information can be transmitted through the LCMP network 900, and it is passed to the interprocessor communication drive-access program 206. The interprocessor communication drive-access program 206 sends out the received file access demand to the LCMP network 900, and transmits it to the target file server. Here, it explains that a file server 110 is the target file server. In the file server 110 which is the destination of a file access demand, the interprocessor communication drive-access program 212 receives this demand, and the interprocessor communication protocol control program 213 is passed. The interprocessor communication protocol control program 213 will pass the information about file enclosure to the file enclosure access-control program 612 within the file access control program 611, if this recognizes that it is the file access demand sent from the master file server 100, i.e., other file servers. The file enclosure access program 612 is accessed to the file of the purpose of file enclosure.

[0029] Next, the method of storing of the file in an example is shown in drawing 10 and drawing 11 . When the monitoring of the load of a file server is carried out by the load information monitoring program and it stores a file and its duplicate file in two file servers with the lightest load at the time of file writing, the combination of two file enclosure in which the mirror file of the same content is stored so that it may be shown drawing 10 becomes less fixed. On the other hand, it can always fix, it can have the pair of two file servers which store a file and its duplicate file, and the file data of the pair of file enclosure can also be completely considered as mirror composition like drawing 11 . The pair of the file server which judges whether the load of which pair is light among two or more pairs of the file server together put also in this case, and stores each file can be determined. It can replace with these, and it can also constitute so that all file servers may overlap mutually and may store the file data of the same content.

[0030] As mentioned above, according to this example, it becomes possible to read with the file distribution program 502 and to access to a file server with few file access loads by the demand scheduling program 503 by managing the number of the access demand which processing has not finished yet by the load information monitoring program 505, and carrying out the monitoring of the file access load to each file server. And since a file and its duplicate file are stored in two or more file servers, even if the access demand from a client computer to the same directory and the same file occurs simultaneously, it can distribute to two or more file servers. That is, even when ****(ing) two or more file servers, sharing a file among many client computers on a network and two or more directories and files with the same client computer are accessed simultaneously, generating of the bottleneck by concentration of access to a specific file server and the fall of the throughput accompanying it can be prevented, and access of the high throughput from a client computer can be realized.

[0031] In addition, although the case where the number of the file enclosure to which each processor performs file access control in the above-mentioned example was one respectively was shown, even if it is the composition which can connect and carry out the access control of two or more sets of the file enclosure to each file server, it is clear that the effect taken by this example and the same effect are acquired.

[0032] Furthermore, even if each program, such as a file enclosure discernment program shown by this example, file management, and a file access control program, consists of hardware, it is

clear that the effect taken by the above-mentioned this example and the same effect are acquired.
[0033] Another example of this invention is shown in drawing 12 - drawing 17 , respectively. The example shown in drawing 12 is the composition of having prepared the remote file-access-operation program which existed only in the master file server 100 in other file servers 110, 120, and 130, respectively. Each file servers 100, 110, 120, and 130 are connected through the LCMP network 900, respectively, and each-other data communication is performed. Furthermore, each file servers 100, 110, 120, and 130 are connected to Local Area Network 50. Therefore, it becomes possible to receive the processing demand which includes a file access demand or file access demand of a client computer through Local Area Network 50 in all file servers. For example, if the processing demand from a client computer communicates to a file server 110, the remote file-access-operation program 311 will interpret the content of communication, will extract a file access demand, and will start a communication control program 211. A communication control program 211 is carried out through the LCMP network 900, and transmits a file access demand to the master file server 100. The master file server 100 determines the file server which stores a file by file management 501 like the example of drawing 1 , or the file server which performs a readout.
[0034] It is the composition of having replaced the example with the composition in which file management exists in the example of drawing 1 only at the specific file server 100, and having prepared file management in drawing 13 at all file servers. Therefore, there is no distinction of a master and a slave among file servers 100, 110, 120, and 130. Furthermore, the storage region of each file enclosure 700, 710, 720, and 730 is quadrisected, respectively. Among [1-1] the divided fields, although 1-2, 1-3, and 1-4 were prepared in the 1st file server 100, they are a field which file management 501 manages. Moreover, although a field 2-1, 2-2, 2-3, and 2-4 were prepared in the 2nd file server 110, file management 511 prepared a field 3-1, 3-2, 3-3, and 3-4 in the 3rd file server 120 and file management 521 prepared a field 4-1, 4-2, 4-3, and 4-4 in the 4th file server 130, file management 531 is the field managed, respectively. That is, each file server has mutually the field which can manage self on the file enclosure in which other file servers take charge of an access control and to perform. The remote file-access-operation program 301 prepared only in the 1st file server 100 has the function to distribute the extracted file write request to the file management of each file server one by one. According to this example, distributed management of the file in a file server system can be carried out by four sets of file servers, and it becomes possible to perform file management to 4 sets to simultaneous parallel within one set of a file server system. therefore -- at the same time it acquires the effect of the rapid access of this invention -- a twist -- much more load distribution becomes possible and the effect that the degree of parallel of processing is raised and a file server system throughput can be improved is also acquired
[0035] The example shown in drawing 14 is the composition of having prepared the remote file-access-operation program which existed in the chisel at the 1st file server 100 in all file servers, in the example shown in drawing 13 . The effect of becoming possible to receive the processing demand including the file access demand or file access demand which minded LAN in all file servers is acquired at the same time the effect that a throughput can be improved by improvement in the load distribution by distributed management of a file and parallelism is acquired according to this example.
[0036] The example shown in drawing 15 is the file server system of the false loose-coupling multiprocessor composition which substitutes Local Area Network 50 for communication between file servers, without preparing a LCMP network between each file server. The internal configuration of each file servers 100, 110, 120, and 130 is the same as that of the example's shown in drawing 14 . Also in the file server system of this example, it is clear that the effect acquired in each deformation example of the 1st example described above and the same effect are acquired.
[0037] The example shown in drawing 16 is an example which takes the composition connected to Local Area Network 50 through the bridge equipment 60 in which the false file server system of loose-coupling multiprocessor composition has the function which delivers a file access

demand to each file server, and realized the same function as an example to drawing 15's . Communication between each file servers 100, 110, 120, and 130 is performed using the network inside bridge equipment 60, and, in communication with an alien-machine system, is performed through bridge equipment. The monitoring of the load situation of each file server is carried out with bridge equipment 60, and if bridge equipment receives the file access demand from a client computer, it will select the file server which transmits a file access demand based on a load situation. Also in the file server system of this example, the effect acquired in the example's of drawing 14 described previously and the same effect are acquired.
[0038] The examples shown in drawing 17 are the example shown in drawing 14 , and an example which realized the same function in the file server system of close coupling multiprocessor composition. The file server system of this example performs communication between file servers through this, using a system bus 80 as an interprocessor communication means. The network communication means connected to the system bus 80 performs communication with a client computer. Also in the file server system of this example, the effect acquired in each example described previously and the same effect are acquired.
[0039]
[Effect of the Invention] According to this invention, it can access to a file server with few file access loads. And since a file and its duplicate file are stored in two or more file servers, the access demand from a client computer to the same directory and the same file can also be distributed according to the load situation to two or more file servers. Therefore, by the system which **** two or more file servers and shares a file among many client computers on a network, even when two or more directories and files with the same client computer are accessed simultaneously, generating of the bottleneck by concentration of access to a specific file server and the fall of the throughput accompanying it can be prevented, and access of the high throughput from a client computer can be realized.

[Translation done.]

* NOTICES *

1.This document has been translated by computer. So the translation may not reflect the original precisely.
2.**** shows the word which can not be translated.
3.In the drawings, any words are not translated.

DESCRIPTION OF DRAWINGS

[Brief Description of the Drawings]
[Drawing 1] It is the block diagram showing the whole example composition of this invention.
[Drawing 2] It is the block diagram showing the detailed composition of the principal part of an example.
[Drawing 3] It is the block diagram showing the program composition of the master file server of an example.
[Drawing 4] It is the block diagram showing the composition of the file management of an example.
[Drawing 5] It is the conceptual diagram showing an example of the file attribute table in an example.
[Drawing 6] It is the conceptual diagram showing another example of the file attribute table in an example.
[Drawing 7] It is the block diagram showing the program composition of other file servers of an example.
[Drawing 8] It is the flow chart which shows the flow of the file access operation in an example.
[Drawing 9] It is the flow chart which shows the flow of processing of the file management which can be set for it to be able to set in the example.
[Drawing 10] It is the conceptual diagram showing an example of the file storing gestalt in an example.
[Drawing 11] It is the conceptual diagram showing another example of the file storing gestalt in an example.
[Drawing 12] It is the block diagram showing another example of this invention.
[Drawing 13] It is the block diagram showing still more nearly another example of this invention.
[Drawing 14] It is the block diagram showing still more nearly another example of this invention.
[Drawing 15] It is the block diagram showing still more nearly another example of this invention.
[Drawing 16] It is the block diagram showing still more nearly another example of this invention.
[Drawing 17] It is the block diagram showing still more nearly another example of this invention.
[Description of Notations]
10, 20, 30 -- A client computer, 11 — Application program, 50 [-- Master file server,] -- A network, 90 -- A file server system, 100 110, 120, 130 -- A file server, 200, 210, 220, 230 -- Communications control means, 300 -- A remote file AKUSEKU processing means, 500 -- File management means, 508 [-- A file access control means, 700, 710, 720, 730 / — A file storing means, 900 / -- LCMP network.] -- A file attribute table, 509 -- A load information table, 600, 610, 620, 630

[Translation done.]

(19)日本国特許庁（ＪＰ）　(12) **公開特許公報（Ａ）**　(11)特許出願公開番号

特開平6－332782

(43)公開日　平成６年(1994)12月２日

(51)Int.Cl.[5]		識別記号	庁内整理番号	ＦＩ	技術表示箇所
Ｇ０６Ｆ	12/00	５４５　Ｂ	8944－5B		
	15/16	３７０　Ｍ	7429－5L		
		３８０　Ｚ	7429－5L		

審査請求　未請求　請求項の数21　ＯＬ　（全 21 頁）

(21)出願番号　特願平6－50126

(22)出願日　平成６年(1994)３月22日

(31)優先権主張番号　特願平5－61602

(32)優先日　平５(1993)３月22日

(33)優先権主張国　日本（ＪＰ）

(71)出願人　000005108
株式会社日立製作所
東京都千代田区神田駿河台四丁目６番地

(71)出願人　000233011
日立コンピュータエンジニアリング株式会社
神奈川県秦野市堀山下１番地

(72)発明者　秋沢　充
東京都国分寺市東恋ケ窪１丁目280番地
株式会社日立製作所中央研究所内

(74)代理人　弁理士　小川　勝男

最終頁に続く

(54)【発明の名称】　ファイルサーバシステム及びそのファイルアクセス制御方法

(57)【要約】

【目的】　各々のファイル格納装置をアクセスする複数のファイルサーバがネットワークを介して並設されたファイルサーバシステムにいて、複数のクライアントから特定のファイルサーバにアクセス要求が集中することによるスループットの低下を防ぐ。

【構成】　ファイルサーバシステム９０を構成するファイルサーバ１００、１１０、１２０、１３０のうちのマスタファイルサーバ１００には、各ファイルサーバの負荷状況を計測・管理する負荷情報テーブル５０８とファイルブロックごとのアクセス担当のファイルサーバを記録・管理するファイル属性テーブルとを用いてファイルを管理し、とくにファイル書き込み時には負荷の軽いファイルサーバを選定し、選定されたファイルサーバにクライアント計算機１０、２０、３０から伝送されたファイルアクセス要求を分配するファイル管理手段を備える。

(図1)

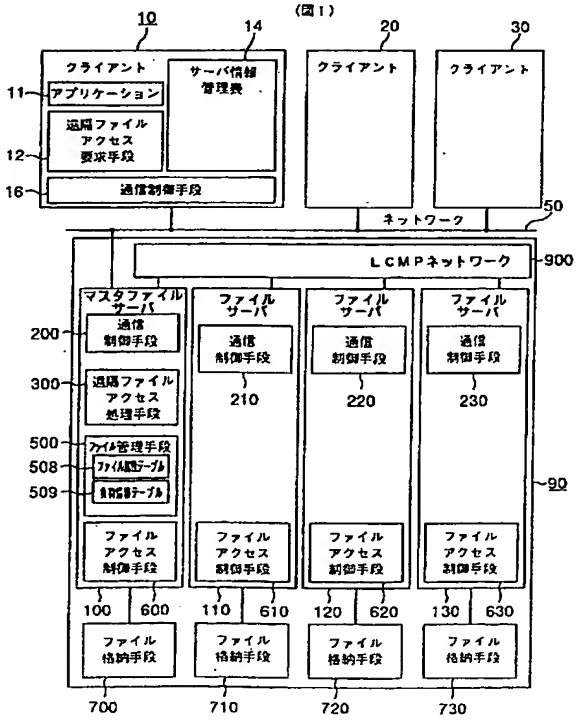

【特許請求の範囲】

【請求項１】ネットワーク上に並接された複数のファイルサーバを有し、複数のクライアント計算機間で上記ファイルサーバに分散配置されたファイルを共有するファイルサーバシステムにおいて、

上記複数のファイルサーバの各々に、

ファイルを格納するファイル格納手段と、

上記ネットワークを介して他のファイルサーバとの通信制御を行う第一の通信制御手段と、

ファイルアクセス要求を受け付けて上記ファイル格納手段に対してファイルアクセスを行なうファイルアクセス制御手段を設け、

上記複数のファイルサーバのうち特定のファイルサーバに、

上記クライアント計算機との通信制御を行なう第二の通信制御手段と、

上記クライアント計算機から発行されたファイルアクセス要求の通信プロトコルを管理する遠隔ファイルアクセス処理手段と、

上記複数のファイルサーバの各々の負荷状況を計測する負荷情報モニタリング手段と、

上記負荷情報モニタリング手段によって計測した負荷状況を参照して上記複数のファイルサーバからファイルアクセスを行なうファイルサーバを選定し、選定されたファイルサーバが自己のファイルサーバであるときに自己のファイルサーバのファイルアクセス制御手段に対してファイルアクセス要求を発行し、選定されたファイルサーバが他のファイルサーバであるときに上記第１の通信制御手段を介してその選定されたファイルサーバのファイルアクセス制御手段に対してファイルアクセス要求を発行するファイルアクセス要求を発行するファイルアクセス要求配分手段を更に設けたことを特徴とするファイルサーバシステム。

【請求項２】上記負荷情報モニタリング手段は、上記複数のファイルサーバの各々における未処理のファイルアクセス要求数を計数する手段を含む請求項１に記載のファイルサーバシステム。

【請求項３】上記ファイルアクセス要求配分手段は、

上記クライアント計算機から発行されたファイルアクセス要求が書き込み要求か読み出し要求かを判定する書き込み読み出し判定手段と、

ファイル書き込み時には前記負荷情報モニタリング手段によって計測した負荷状況を参照してファイルを格納するファイルサーバを選定するファイル分割配置手段と、

ファイル読み出し時には上記負荷情報モニタリング手段によって計測した負荷状況を参照して読み出し対象ファイルが格納されているファイルサーバから読み出しの対象とするファイルサーバを選定するアクセス対象ファイルサーバ・スケジューリング手段を含むことを特徴とする請求項１に記載のファイルサーバシステム。

【請求項４】上記ファイル分割配置手段は、書き込み対象のファイルを格納するファイルサーバを少なくとも二つ以上選定するファイル分割配置手段を設けたことを特徴とする請求項３に記載のファイルサーバシステム。

【請求項５】上記ファイル分割配置手段は、書き込み対象のファイルを格納するファイルサーバを少なくとも二つ以上選定し、上記アクセス対象ファイルサーバ・スケジューリング手段は読み出し対象のファイルが格納されているファイルサーバのうち前記負荷情報モニタリング手段により取得された負荷状況を参照し負荷の軽いファイルサーバを読み出し対象のファイルサーバとして選定することを特徴とする請求項３に記載のファイルサーバシステム。

【請求項６】上記ファイル分割配置手段は、ファイルを格納するファイルサーバを選定する際に、該ファイルと該ファイルサーバの対応関係を示すファイル属性テーブルを生成し、上記アクセス対象サーバスケジューリング手段は上記ファイル属性テーブルを参照して読み出し対象のファイルが格納されているファイルサーバを特定することを特徴とする請求項３に記載のファイルサーバシステム。

【請求項７】上記第二の通信制御手段と上記遠隔ファイルアクセス処理手段とを上記複数のファイルサーバのうちの少なくとも二つ以上にそれぞれ設けたことを特徴とする請求項１に記載のファイルサーバシステム。

【請求項８】上記負荷情報モニタリング手段と上記ファイルアクセス要求配分手段とを上記複数のファイルサーバのうちの少なくとも二つ以上にそれぞれ設けたことを特徴とする請求項１に記載のファイルサーバシステム。

【請求項９】上記負荷情報モニタリング手段と上記ファイルアクセス要求配分手段とを上記複数のファイルサーバのうちの少なくとも二つ以上にそれぞれ設けたことを特徴とする請求項７に記載のファイルサーバシステム。

【請求項１０】上記クライアント計算機は上記ネットワークに接続され、上記クライアント計算機と上記特定のファイルサーバとの通信制御の機能は上記第二の通信制御手段の代りに上記第一の通信制御手段が果たすとを特徴とする請求項１に記載のファイルサーバシステム。

【請求項１１】上記クライアント計算機は第１のネットワークに接続され、上記複数のファイルサーバは第２のネットワークに接続され、上記第１、第２のネットワークは上記クライアント計算機からのファイルアクセス要求を上記特定のファイルサーバへ配分するブリッジ手段で接続されることを特徴とする請求項１に記載のファイルサーバシステム。

【請求項１２】上記第一の通信制御手段はシステムバスを介して他のファイルサーバとの通信を行うことを特徴とする請求項１に記載のファイルサーバシステム。

【請求項１３】上記システムバスは上記複数のファイルサーバ間の通信のみに用いる専用バスであることを特徴

とする請求項１２に記載のファイルサーバシステム。
【請求項１４】ネットワーク上に並接された複数のファイルサーバを有し、複数のクライアント計算機間で上記ファイルの複数のファイルサーバに分散配置されたファイルを共有するファイルサーバシステムにおけるファイルアクセス制御方法において、
上記複数のファイルサーバの各々の負荷情報を計測し、
クライアント計算機から上記ネットワークを介して発行されたファイルアクセス要求が受け付られた際に、上記負荷情報を参照してファイルアクセスを行うファイルサーバを選定し、
上記選定ファイルサーバに対してファイルアクセス要求を配分する、
とのステップを含むファイルアクセス制御方法。
【請求項１５】上記の負荷情報を計測するステップは上記複数のファイルサーバの各々の未処理のファイルアクセス要求数を計数するステップを含む請求項１４に記載のファイルアクセス制御方法。
【請求項１６】上記ファイルアクセスを行なうファイルサーバを選定するステップは、
クライアント計算機から発行されたファイルアクセス要求が書き込み要求か読み出し要求かを判定し、
ファイル書き込み時には計測した負荷状況を参照してファイル格納対象のファイルサーバを選定し、
ファイル読み出し時には計測した負荷状況を参照して読み出し対象ファイルが格納されているファイルサーバから読み出し対象のファイルサーバを選定する、
とのステップを含むことを特徴とする請求項１４に記載のファイルアクセス制御方法。
【請求項１７】請求項１６に記載のファイルアクセス制御方法において、上記のファイル格納対象のファイルサーバを選定するステップでは書き込み対象ファイルを格納するファイルサーバを少なくとも二つ以上選定することを特徴とするファイルアクセス制御方法。
【請求項１８】請求項１６に記載のファイルアクセス制御方法において、上記の読み出し対象のファイルサーバを選定するステップでは読み出し対象ファイルが格納されている複数のファイルサーバのうち計測した負荷情報に基づき負荷の軽いファイルサーバを選択して読み出し対象のファイルサーバとすることを特徴とするファイルアクセス制御方法。
【請求項１９】請求項１６に記載のファイルアクセス制御方法において、ファイルを格納するファイルサーバを選定する際に、該ファイルと該ファイルサーバの対応関係を示すファイル属性テーブルを生成し、上記アクセス対象サーバスケジューリング手段は上記ファイル属性テーブルを参照して読み出し対象のファイルが格納されているファイルサーバを特定する
【請求項２０】請求項１４に記載のファイルアクセス制御方法において、上記ファイルアクセス対象ファイルサーバを選定するステップは、
少なくとも二つ以上のファイルサーバで各ファイルサーバの負荷情報を計測し、
クライアント計算機から発行されたファイルアクセス要求を上記負荷情報を計測するファイルサーバで受け取り、
上記負荷情報を参照してファイルアクセス対象ファイルサーバを選定し、
ファイルアクセス対象ファイルサーバとして選定したファイルサーバに対してファイルアクセス要求を配分することを特徴とする高速ファイルアクセス制御方法。
【請求項２１】請求項２０に記載のファイルアクセス制御方法において、上記ファイルアクセス対象ファイルサーバを選定するステップでは、ファイルアクセスがファイル書き込みである時には負荷の少ないファイルサーバを書き込み対象ファイルサーバとして選定し、ファイルアクセスがファイル読み出しである時にはファイルが格納されているファイルサーバから負荷の少ないファイルサーバを読み出し対象ファイルサーバとして選定することを特徴とするファイルアクセス制御方法。
【発明の詳細な説明】
【０００１】
【産業上の利用分野】本発明はワークステーションやサーバ等の計算機システムに関わり，特にマルチプロセッサ構成の計算機システムにおける、二次記憶装置に格納されたファイルを高速にアクセスするファイルサーバシステム及びそのファイルアクセス制御方法に関する。
【０００２】
【従来の技術】近年、計算機のネットワーク化が進展してきている。これに伴い、計算機間で共有するファイルを一括して管理するファイルサーバの需要が高まっている。これは、低コストでファイルシステムを構築できるためである。すなわち、ファイルサーバを用いることによって複数の計算機間でファイルの共有が可能となるため、同一のファイルを複数の計算機間で複数コピーして所持しないですむようになるからである。ファイルサーバには通常ネットワーク対応ファイルシステムが搭載されており、同じネットワークに接続されたクライアント側の計算機にもネットワーク対応ファイルシステム・アクセスプログラムを搭載することによって、あたかもクライアント計算機自身に格納されているファイルであるかのようにアクセスすることが可能になる。そのため、ネットワークに接続されているどのクライアント計算機からも、ファイルサーバ上に蓄積、管理されているファイルに対してアクセスすることが可能となり、複数のクライアント計算機間でのファイルの共有が実現される。
【０００３】ネットワーク対応ファイルシステムについての記述は、Managing NFS and NIS(Hal Stern、O'Reilly & Associates、Inc、 June １９９１、 p.１１３～p.１５９)にある。

【０００４】しかし、ファイルサーバ内のファイルをネットワーク対応ファイルシステムを用いて共有する場合には、性能上の問題が生じることがある。すなわち多数のクライアント計算機から同時にファイルアクセスを行なう場合には、ファイルサーバに負荷が集中し、直ちにアクセス結果が得られない状況が発生する。

【０００５】そのため、ファイルサーバへの負荷が過大になりクライアント計算機のアクセス・スループットが低下する場合には、複数台のファイルサーバをネットワーク上に並接し複数クライアント計算機からのアクセス要求を分散することが行なわれている。各クライアント計算機は、ネットワーク上に設置されている全ファイルサーバの情報を管理し、この管理情報を参照してアクセス対象のファイルが存在するファイルサーバに対してアクセス要求を発行する。これにより、各クライアント計算機のアクセス対象ファイルが別々のファイルサーバに格納されている場合には、負荷を分散することが可能になり、アクセススループットを向上することができる。

【０００６】クライアント・アンド・サーバ構成ではないが、一つのメインプロセッサが複数のデータファイルの全体の管理を行い、これらデータ・ファイルは複数のサブ・プロセッサに分散配置されているとの点で上記システムと類似するシステムが日本公開特許０４－４８３５２号（１９９２）に記載される。

【０００７】

【発明が解決しようとする課題】上述したように複数台のファイルサーバを設置して多数のクライアント計算機間でファイルを共有したとしても、以下の問題が残る。

【０００８】クライアント計算機はファイルサーバの負荷状況とは全く無関係にファイルが存在するファイルサーバをアクセスするため、複数のクライアント計算機が一つのファイルサーバに同時にアクセス要求を出すことがあり、その場合には該当ファイルサーバがボトルネックとなり、スループットが低下してしまうという問題が生じる。とくに、複数のクライアント計算機が同一のディレクトリや同一のファイルに同時にアクセスすると、その性能低下が甚だしくなる。この問題はその性格上ファイルサーバの設置台数を増やしても解決できるものではない。

【０００９】本発明の目的は、多数のクライアント計算機間でのファイルの共有を行なうために複数のファイルサーバを並接したネットワークにおいて、複数のクライアント計算機が同一のディレクトリやファイルに同時にアクセスした場合でも、特定のファイルサーバへのアクセスの集中によるボトルネックの発生とそれに伴うスループットの低下を防ぐことができるファイルサーバシステムとそのファイルアクセス制御方法を提供することである。

【００１０】

【課題を解決するための手段】本発明のファイルアクセス制御方法の一つの特徴は、ネットワーク上に並接された複数のファイルサーバを有し、複数のクライアント計算機間で複数のファイルサーバに分散配置されたファイルを共有するファイルサーバシステムにおいて、上記複数のファイルサーバの各々の負荷情報を計測し、クライアント計算機から上記ネットワークを介して発行されたファイルアクセス要求が受け付られた際に、上記負荷情報を参照してファイルアクセスを行うファイルサーバを選定し、上記選定ファイルサーバに対してファイルアクセス要求を配分する、とのステップを含むファイルアクセス制御方法にある。

【００１１】より具体的にいえば、クライアント計算機からのファイルアクセス要求が新たなファイルの書き込み要求である場合には複数のファイルサーバの負荷情報を計測して負荷の最も軽いファイルサーバを選定し、そのファイルサーバにファイル書き込み要求を発行する。あるいは、ミラー構成のファイルを作製する場合には、負荷の軽い複数のファイルサーバを選定し、それらのファイルサーバそれぞれにファイル書き込み要求を発行する。また、クライアント計算機からのファイルアクセス要求がファイル読み出し要求であり、読み出し対象のファイルがミラー構成にされている場合には、読み出し対象のファイルが格納された複数の複数のファイル格納装置それぞれを受け持つ複数のファイルサーバの負荷情報を計測して負荷の最も軽いひとつのファイルサーバを選定し、そのファイルサーバにファイル読み出し要求を発行する。

【００１２】上記の負荷情報の計測は、上記複数のファイルサーバの各々の未処理のファイルアクセス要求数を計数することにより行う。このために、複数のファイルサーバのうちの少なくとも一つをマスタ・ファイルサーバとし、このマスタ・ファイルサーバには、複数のファイルサーバの各々の未処理のファイルアクセス要求数を負荷情報テーブルに記録・更新する負荷情報モニタリング手段を設ける。また、このマスタ・ファイルサーバには、各ファイルとそのファイルの書き込みを受け持ったファイルサーバの対応関係を記録するファイル属性テーブル、および上記負荷情報テーブルを用いてクライアント計算機からのファイルアクセス要求を分配する手段を設ける。

【００１３】本発明にしたがうファイルサーバシステムの代表的構成は、ネットワーク上に並接された複数のファイルサーバを有し、複数のクライアント計算機間で上記ファイルサーバに分散配置されたファイルを共有するファイルサーバシステムにおいて、上記複数のファイルサーバの各々には、ファイルを格納するファイル格納手段と、上記ネットワークを介して他のファイルサーバとの通信制御を行う第一の通信制御手段と、ファイルアクセス要求を受け付けて上記ファイル格納手段に対してファイルアクセスを行なうファイルアクセス制御手段を設

け、一方、上記複数のファイルサーバのうち特定のファイルサーバにはこれらに加えて、上記クライアント計算機との通信制御を行なう第二の通信制御手段と、上記クライアント計算機から発行されたファイルアクセス要求の通信プロトコルを管理する遠隔ファイルアクセス処理手段と、上記複数のファイルサーバの各々の負荷状況を計測する負荷情報モニタリング手段と、上記負荷情報モニタリング手段によって計測した負荷状況を参照して上記複数のファイルサーバからファイルアクセスを行なうファイルサーバを選定し、選定されたファイルサーバが自己のファイルサーバであるときに自己のファイルサーバのファイルアクセス制御手段に対してファイルアクセス要求を発行し、選定されたファイルサーバが他のファイルサーバであるときに上記第１の通信制御手段を介してその選定されたファイルサーバのファイルアクセス制御手段に対してファイルアクセス要求を発行するファイルアクセス要求配分手段を更に設けた、との構成である。

【００１４】

【作用】このような方法及びシステム構成によれば、ファイルアクセス負荷の少ないファイルサーバへアクセスを行なうことができる。しかも、ファイルとその複製ファイルを複数のファイルサーバに格納するため同一のディレクトリやファイルに対するクライアント計算機からのアクセス要求も複数のファイルサーバにその負荷状況に応じて分散することができる。すなわち、ネットワーク上に複数のファイルサーバを並接し多数のクライアント計算機間でファイルの共有を行なう際に、複数のクライアント計算機が同一のディレクトリやファイルに同時にアクセスした場合でも、特定のファイルサーバへのアクセスの集中によるボトルネックの発生とそれに伴うスループットの低下を防ぐことができ、クライアント計算機からの高スループットのアクセスを実現できることになる。

【００１５】

【実施例】本発明の実施例の構成を図１を参照して説明する。

【００１６】疎結合マルチプロセッサで構成するファイルサーバシステム９０と、クライアント計算器１０、２０、３０とはローカルエリアネットワーク５０により接続される。クライアント計算機１０、２０、３０の各々ではアプリケーションプログラム１１が実行され、これによってファイルアクセス要求が発生すると、遠隔ファイルアクセス要求発生手段１２からファイルサーバシステム９０へファイルアクセス要求が発行される。具体的には、ファイルアクセス要求は、通信制御手段１６から、ファイルサーバシステム９０を構成する４台のファイルサーバ１００、１１０、１２０、１３０のうちの特定の一つであるファイルサーバ１００へローカルエリアネットワーク５０を介して伝送される。４台のファイルサーバ１００、１１０、１２０および１３０はそれぞれがファイル格納手段７００、７１０、７２０および７３０のアクセスを個別に受け持つ。そのためにファイルサーバ１００、１１０、１２０および１３０にはそれぞれファイルアクセス制御手段６００、６１０、６２０および６３０が形成される。またファイルサーバ１００、１１０、１２０および１３０はＬＣＭＰネットワーク９００を介して互いに通信する。このために通信制御手段２００、２１０、２２０、２３０がそれぞれのファイルサーバに形成される。

【００１７】本実施例では、上記特定のファイルサーバ１００をマスタファイルサーバと呼ぶ。マスタファイルサーバ１００は、さらにクライアント計算機から発行されたファイルアクセス要求を受け付けるための遠隔ファイルアクセス処理手段３００、および個々のファイルサーバの負荷が大きく偏らないようファイルの分散配置を管理し、且つ受け付けたファイルアクセス要求を個々のファイルサーバに振り分けるファイル管理手段５００が形成される。このファイル管理およびファイルアクセス要求の振り分けのために、ファイル属性テーブル５０８および負荷情報テーブル５０９が用いられる。クライアント計算機のサーバ情報管理表１４には、マスタファイルサーバ１００の情報、つまりマスタファイルサーバ１００のマシンアドレスが格納される。

【００１８】図２はマスタファイルサーバ１００の装置構成を示すブロック図である。マスタファイルサーバ１００はシステムバス１０７で互いに接続されたプロセッサ１０１、主メモリ１０２、ネットワークインタフェース回路１０３及びＬＣＭＰネットワークインタフェース回路１０４を含む。システム立ちあげ時に、図示しない２次記憶装置から遠隔ファイルアクセス処理プログラム３０１、ファイル管理プログラム５０１、ファイルアクセス制御プログラム６０１及び通信制御プログラム２０１がそれぞれ主メモリ１０２にロードされ、これにより図１に示した遠隔ファイルアクセス処理手段３００、ファイル管理手段５００、ファイルアクセス制御手段６００及び通信制御手段２００が形成される。マスタファイルサーバ１００が書き込み読み出しを受け持つファイル格納手段７００は、図２に示す通り磁気ディスク装置であり、システムバス１０７に接続される。なおファイル格納手段７００は光磁気ディスク装置や光ディスク装置、またその他の二次記憶装置であっても構わない。

【００１９】図１のマスタファイルサーバ１００以外のファイルサーバ１１０、１２０及び１３０も、図２に示すのとほぼ同様な構成をそれぞれ有する。但し、これらの主メモリには遠隔ファイルアクセスプログラム並びにファイル管理プログラムはロードされない。またローカルエリアネットワーク５０への接続のためのネットワークインターフェース回路１０３も不要である。

【００２０】図３はマスタファイルサーバ１００のプロ

グラム構成を示す。通信制御プログラム２０１は、ローカルエリアネットワーク５０とマスタファイルサーバ１００とのインタフェースとなるネットワークアクセスプログラム２０５と、ＬＣＭＰネットワーク９００とマスタファイルサーバ１００とのインタフェースとなるプロセッサ間通信装置アクセスプログラム２０６と、ネットワークアクセスプログラム２０５から受け取った要求を遠隔ファイルアクセス処理プログラム３０１が解釈できるようにプロトコル変換して渡すネットワーク通信プロトコル制御プログラム２０７と、後で説明するファイルアクセス制御プログラム６０１で解釈された他のファイルサーバへのアクセス要求をプロトコル変換してプロセッサ間通信装置アクセスプログラム２０６に渡すプロセッサ間通信プロトコル制御プログラム２０８から構成される。ファイルアクセス制御プログラム６０１は、ファイル管理プログラム５０１からファイル格納装置およびファイルサーバに関する情報を受け取り、自己のプロセッサ１０１がアクセス制御を受け持つファイル格納装置７００にアクセスする場合にはファイル格納装置アクセスプログラム６０４へファイル格納装置に関する情報を渡し、他のファイルサーバ１１０～１３０がアクセス制御を受け持つファイル格納装置７１０～７３０にアクセスする場合にはプロセッサ間通信プロトコル制御プログラム２０８にファイル格納装置に関する情報を渡して他のファイルサーバにアクセスを依頼するファイル格納装置識別プログラム６０３と、ファイル格納装置識別プログラム６０３からファイル格納装置に関する情報を受け取り、目的のファイルを格納する磁気ディスク装置７００をアクセスするファイル格納装置アクセスプログラム６０４とから構成される。

【００２１】ファイル管理プログラム５０１については、さらに詳細なプログラム構成を示す図４をも参照して説明する。ファイル管理プログラム５０１は、ファイル属性テーブル５０８と負荷情報テーブル５０９を管理し、またこれらを用いて遠隔ファイルアクセス処理プログラム３０１から渡されたファイルアクセス要求をファイルサーバの情報、ファイル格納装置の情報およびファイル格納装置内のファイル格納位置の情報に変換してファイルアクセス制御プログラム６０１に渡す。ファイルの分散配置及びそれにしたがうアクセス対象のファイルサーバ選定の処理をおこなう。そのために、ファイル管理プログラム５０１は、遠隔ファイルアクセス処理プログラム３０１から渡されるファイルアクセス要求を受け付けて、それが書き込み要求か読み出し要求を判別するファイルアクセス要求受付プログラム５０４と、ファイル書き込み時にどのファイルサーバによりファイルを書き込むかを決定するファイル分散配置プログラム５０２と、読み出し時にどのファイルサーバにアクセスを行なうかを決定する読み出し要求スケジューリングプログラム５０３と、各ファイルサーバの未処理アクセス要求数を計数することにより各ファイルサーバの負荷状況を計測する負荷情報モニタリングプログラム５０５とから構成される。ファイル属性テーブル５０８には、各ファイルに対応しそのファイルが格納されているファイルサーバ識別子とファイル格納装置識別子およびファイル格納装置内のファイル格納位置の情報が保持される。負荷情報テーブル５０９には各ファイルサーバの未処理アクセス要求数が保持される。

【００２２】次に、ファイル属性テーブルの第１の例を図５に示す。この例は、ひとつのファイルを分割せずに、あるいは複製を持たずに、ファイル単位での分散配置を行う場合の例である。ファイル属性テーブルは、（１）ファイル属性領域、（２）ディスクブロックインデックス領域の二つの領域から構成される。ファイル属性領域は、ファイルサイズ、ファイル格納モード、ファイルアクセス・プロセッサ識別子、ファイル格納デバイス識別子の各エントリからなる。ファイル格納モードにはローカルとリモートがあり、ファイル属性テーブルを管理している自己のファイルサーバがアクセス制御を受けもつファイル格納装置にファイルが格納されているのか、あるいは他のファイルサーバがアクセス制御を受けもつファイル格納装置にファイルが格納されているのかを示す。ファイルアクセス・プロセッサ識別子は、ファイル属性テーブルに対応するファイルが格納されているファイル格納装置のアクセス制御を受けもつファイルサーバの識別子を示す。ファイル格納デバイス識別子は、ファイルが格納されているファイル格納装置を示す。ディスクブロックインデックス領域は、ファイルを構成する一連の各ディスクブロックの、ファイル格納装置内での位置を示すインデックスから構成されている。

【００２３】次に、ファイル属性テーブルの第２の例を図６に示す。この例は、ひとつのファイルを分割して分散配置を行う場合の例である。ファイル属性テーブルは、図５の第１の例と同様に(1)ファイル属性領域、(2)ディスクブロックインデックス領域の二つの領域から構成される。ただし、各ディスクブロックごとにファイル属性領域が存在し、その格納場所を指定している。図６に示す例では、ファイルを構成する第１のデータブロックは第１のファイルサーバがアクセス制御を行う１番のディスク装置のインデックス１００番の位置に存在することを示している。以下、第２のデータブロックは第２のファイルサーバがアクセス制御を行う１番のディスク装置のインデックス２００番の位置に、第３のデータブロックは第３のファイルサーバがアクセス制御を行う１番のディスク装置のインデックス３００番の位置に存在することを示している。

【００２４】一方、ファイルサーバ１１０のプログラム構成は図７に示すとおりである。通信制御プログラム２１１は、ＬＣＭＰネットワーク９００を介する伝送のインタフェース、つまりマスタ・ファイルサーバ１００と

のインタフェースとなるプロセッサ間通信装置アクセスプログラム２１２と、プロセッサ間通信装置アクセスプログラム２０６から受け取ったアクセス要求をファイルアクセス制御プログラム６１１が解釈できるようにプロトコル変換して渡すプロセッサ間通信プロトコル制御プログラム２１３から構成される。ファイルアクセス制御プログラムは、プロセッサ間通信プロトコル制御プログラム２０８から受け取ったアクセス要求を解釈し、目的のファイルを格納する磁気ディスク装置７１０をアクセスするファイル格納装置アクセスプログラム６１２で構成される。ファイルサーバ１２０、１３０のプログラム構成も図７と全く同様である。

【００２５】次に本実施例の動作について図８を用いて説明する。

【００２６】クライアント計算機１０、２０、３０のいずれかで、アプリケーションプログラム１１の実行によりファイルアクセス要求またはファイルアクセスを含む処理要求が発生すると、遠隔ファイルアクセス要求プログラム１３が起動され、処理要求はローカルエリアネットワーク５０を介してマスタファイルサーバ１００へ伝送される。ローカルエリアネットワーク５０を介した通信はクライアント計算機とマスタファイルサーバ１００にそれぞれ搭載された通信制御プログラム１７及び２０１を用いて行なわれる。ファイルアクセス要求がファイルサーバ１００に送られると、ファイルサーバ１００の遠隔ファイルアクセス処理プログラム３０１が起動される。遠隔ファイルアクセス処理プログラム３０１では、受信した内容を解析してクライアント計算機からのファイルアクセス要求を抽出し、ファイル管理プログラム５０１にファイルアクセス処理要求を送る。

【００２７】ファイル管理プログラム５０１は図９に示すように動作する。まず、ファイルアクセス要求受付プログラム５０４では、遠隔ファイルアクセス処理プログラム３０１からのファイルアクセス要求を受け付けた後、そのファイルアクセス要求が書き込みなのか読み出しなのかを判断し、書き込みであればファイル分散配置プログラム５０２を起動し、読み出しであれば読み出し要求スケジューリングプログラム５０３を起動する。ファイル分散配置プログラム５０２では、書き込みファイルに対するファイル属性テーブルを作成し、次に負荷情報テーブル５０９を参照してアクセス要求未処理数の少ないファイルサーバをファイルを格納するファイルサーバとして決定する。また、ファイルの複製を作成して他のファイルサーバに格納する場合には再び負荷情報テーブル５０９を参照してアクセス要求未処理数の少ないファイルサーバをファイルの複製を格納するファイルサーバとして決定する。これらファイルと複製ファイルを格納するファイルサーバの情報をサーバ識別子としてファイル属性テーブル５０８に記録し、負荷情報モニタリングプログラム５０５を起動する。読み出し要求スケジューリングプログラム５０３では、読み出すファイルに対するファイル属性テーブル５０８を獲得し、そこから該当ファイルが格納されているファイルサーバを割り出す。ファイルが一つのファイルサーバだけでなく、その複製が他のファイルサーバに格納されている場合には、負荷情報テーブル５０９を参照してファイル本体と複製のどちらを読み出すかを決定し、負荷情報モニタリングプログラム５０５を起動する。負荷情報モニタリングプログラム５０５では、アクセス対象のファイルサーバに対するアクセス要求未処理数をインクリメントすることによって負荷情報をモニタリングし、目的のファイルのどの部分をアクセスするのかを示す情報をファイルアクセス制御プログラム６０１に送り、ファイルアクセス制御プログラム６０１を起動する。

【００２８】ファイルアクセス制御プログラム６０１は図８に示す処理フローステップ６５１、６５２、６５３にしたがって動作する。まずファイル格納装置識別プログラム６０３はファイル管理プログラム５０１から渡された情報を解析しマスタファイルサーバ１００がアクセス制御を受け持つファイル格納装置７００へのアクセスであるのか、他のファイルサーバ１１０～１３０がアクセス制御を受け持つファイル格納装置７１０～７３０へのアクセスであるのかを判断する(ステップ６５１)。前者である場合には、マスタファイルサーバ１００のファイル格納装置アクセスプログラム６０４にファイル格納装置７００に関する情報を渡してファイルアクセスを指示する。ファイル格納装置アクセスプログラム６０４はこれを受けてファイル格納装置７００へのアクセスを開始する(ステップ６５２)。後者である場合には通信制御プログラム２０１の中のプロセッサ間通信プロトコル制御プログラム２０８にファイル格納装置に関する情報を渡し、ファイルアクセスの実行ファイルサーバを指定して要求の転送を依頼する。プロセッサ間通信プロトコル制御プログラム２０８はこれらの情報をＬＣＭＰネットワーク９００を介して転送できるように加工して、プロセッサ間通信装置アクセスプログラム２０６に渡す。プロセッサ間通信装置アクセスプログラム２０６は、受け取ったファイルアクセス要求をＬＣＭＰネットワーク９００に送り出して目的のファイルサーバへ転送する。ここではファイルサーバ１１０が目的のファイルサーバであるとして説明する。ファイルアクセス要求の転送先であるファイルサーバ１１０では、この要求をプロセッサ間通信装置アクセスプログラム２１２が受け取り、プロセッサ間通信プロトコル制御プログラム２１３に渡す。プロセッサ間通信プロトコル制御プログラム２１３は、これがマスタファイルサーバ１００すなわち他のファイルサーバから送られたファイルアクセス要求であることを認識すると、ファイルアクセス制御プログラム６１１内のファイル格納装置アクセス制御プログラム６１２へファイル格納装置に関する情報を渡す。ファイル格納装

置アクセスプログラム６１２はファイル格納装置の目的のファイルに対してアクセスを行なう。

【００２９】次に実施例におけるファイルの格納のしかたを図１０、図１１に示す。負荷情報モニタリングプログラムによってファイルサーバの負荷をモニタリングしておき、ファイル書き込み時に最も負荷の軽い二つのファイルサーバにてファイルとその複製ファイルを格納する場合には、図１０示すように同一内容のミラーファイルが格納される二つのファイル格納装置の組合せは一定ではなくなる。一方、ファイルとその複製ファイルを格納する二つのファイルサーバのペアを常に固定し、もって図１１の様にファイル格納装置のペアのファイルデータを完全にミラー構成とすることもできる。この場合も、組み合わされたファイルサーバの複数のペアの間でいずれのペアの負荷が軽いかを判定して各ファイルを格納するファイルサーバのペアを決定することができる。これらに代えて、すべてのファイルサーバが同一内容のファイルデータを互いに重複して格納する様に構成することもできる。

【００３０】以上、本実施例によれば、負荷情報モニタリングプログラム５０５によってまだ処理が終わっていないアクセス要求の個数を管理し、各ファイルサーバに対するファイルアクセス負荷をモニタリングすることにより、ファイル分散配置プログラム５０２と読み出し要求スケジューリングプログラム５０３によってファイルアクセス負荷の少ないファイルサーバへアクセスを行なうことが可能となる。しかも、ファイルとその複製ファイルを複数のファイルサーバに格納するため同一のディレクトリやファイルに対するクライアント計算機からのアクセス要求が同時に発生しても複数のファイルサーバに分散することができるようになる。すなわち、ネットワーク上に複数のファイルサーバを並接し多数のクライアント計算機間でファイルの共有を行なう際に、複数のクライアント計算機が同一のディレクトリやファイルに同時にアクセスした場合でも、特定のファイルサーバへのアクセスの集中によるボトルネックの発生とそれに伴うスループットの低下を防ぐことができ、クライアント計算機からの高スループットのアクセスを実現できることになる。

【００３１】なお、上記の実施例においては各プロセッサがファイルアクセス制御を行うファイル格納装置が各々１台の場合を示したが、各ファイルサーバに複数台のファイル格納装置を接続しアクセス制御できるような構成であっても、本実施例で示した効果と同様の効果が得られることは明らかである。

【００３２】さらに、本実施例で示したファイル格納装置識別プログラム、ファイル管理プログラム、ファイルアクセス制御プログラム等の各プログラムがハードウェアで構成されていても、上述の本実施例で示した効果と同様の効果が得られることは明らかである。

【００３３】本発明の別の実施例を図１２～図１７にそれぞれ示す。図１２に示す実施例はマスタファイルサーバ１００のみに存在した遠隔ファイルアクセス処理プログラムを他のファイルサーバ１１０、１２０、１３０にもそれぞれ設けた構成である。各ファイルサーバ１００、１１０、１２０、１３０はそれぞれＬＣＭＰネットワーク９００を介して接続され、互いデータ通信が行われる。さらに各ファイルサーバ１００、１１０、１２０、１３０はローカルエリアネットワーク５０に接続される。したがってすべてのファイルサーバにおいてローカルエリアネットワーク５０を介してクライアント計算機のファイルアクセス要求またはファイルアクセス要求を含む処理要求を受け付けることが可能となる。例えば、ファイルサーバ１１０にクライアント計算機からの処理要求が通信されると、遠隔ファイルアクセス処理プログラム３１１は通信内容を解釈してファイルアクセス要求を抽出し、通信制御プログラム２１１を起動する。通信制御プログラム２１１はＬＣＭＰネットワーク９００を介してしてファイルアクセス要求をマスタファイルサーバ１００に伝送する。マスタファイルサーバ１００は、図１の実施例と同様にファイル管理プログラム５０１によりファイルを格納するファイルサーバ、もしくは読みだしを行うファイルサーバを決定する。

【００３４】図１３に実施例は、図１の実施例において特定のファイルサーバ１００のみにファイル管理プログラムが存在する構成に代えて、ファイル管理プログラムをすべてのファイルサーバに設けた構成である。したがって、ファイルサーバ１００、１１０、１２０、１３０の間には、マスタ、スレーブの区別はない。さらに、各ファイル格納装置７００、７１０、７２０、７３０の記憶領域は、それぞれ４分割される。分割された領域のうち１－１、１－２、１－３、１－４は第１のファイルサーバ１００に設けたがファイル管理プログラム５０１が管理する領域である。また、領域２－１、２－２、２－３、２－４は第２のファイルサーバ１１０に設けたがファイル管理プログラム５１１が、領域３－１、３－２、３－３、３－４は第３のファイルサーバ１２０に設けたがファイル管理プログラム５２１が領域４－１、４－２、４－３、４－４は第４のファイルサーバ１３０に設けたがファイル管理プログラム５３１がそれぞれ管理する領域である。つまり、各ファイルサーバは、互いに他のファイルサーバがアクセス制御を受け持つ行うファイル格納装置上に自身が管理可能な領域をもつ。第１のファイルサーバ１００にのみ設けられた遠隔ファイルアクセス処理プログラム３０１は、抽出したファイル書き込み要求を各ファイルサーバのファイル管理プログラムに順次振り分ける機能を有する。本実施例によれば、ファイルサーバシステム内のファイルを４台のファイルサーバで分散管理することができ、１台のファイルサーバシステム内で４組までのファイル管理を同時並列に実行す

ることが可能となる。したがって本発明の高速アクセスの効果を得ると同時に、より一層の負荷分散が可能となり、処理の並列度を上げてファイルサーバシステムのスループットを向上できるという効果も得られる。

【００３５】図１４に示す実施例は図１３に示した実施例において、第１のファイルサーバ１００に、のみに存在した遠隔ファイルアクセス処理プログラムをすべてのファイルサーバに設けた構成である。本実施例によれば、ファイルの分散管理による負荷分散と並列性の向上によりスループットを向上できるという効果が得られると同時に、すべてのファイルサーバにおいてＬＡＮを介したファイルアクセス要求またはファイルアクセス要求を含む処理要求を受け付けることが可能となるという効果が得られる。

【００３６】図１５に示す実施例は、各ファイルサーバ間にＬＣＭＰネットワークを設けずに、ファイルサーバ間の通信をローカルエリアネットワーク５０で代用する擬似的な疎結合マルチプロセッサ構成のファイルサーバシステムである。各ファイルサーバ１００、１１０、１２０、１３０の内部構成は図１４に示した実施例のと同様である。本実施例のファイルサーバシステムにおいても、以上述べた第１の実施例の各変形実施例で得られる効果と同様の効果が得られることが明らかである。

【００３７】図１６に示す実施例は、擬似的な疎結合マルチプロセッサ構成のファイルサーバシステムが、ファイルアクセス要求を各ファイルサーバへ配送する機能を持つブリッジ装置６０を介してローカルエリアネットワーク５０へ接続される構成をとるものであり、図１５のに実施例と同様の機能を実現した実施例である。各ファイルサーバ１００、１１０、１２０、１３０の間の通信はブリッジ装置６０の内部のネットワークを用いて行い、他の計算機システムとの通信の場合にブリッジ装置を介して行う。各ファイルサーバの負荷状況はブリッジ装置６０でモニタリングし、クライアント計算機からのファイルアクセス要求をブリッジ装置が受信すると負荷状況をもとにファイルアクセス要求を送信するファイルサーバを選定する。本実施例のファイルサーバシステムにおいても、先に述べた図１４の実施例のので得られる効果と同様の効果が得られる。

【００３８】図１７に示す実施例は密結合マルチプロセッサ構成のファイルサーバシステムにおいて、図１４に示した実施例と同様の機能を実現した実施例である。本実施例のファイルサーバシステムはプロセッサ間通信手段としてシステムバス８０を用い、これを介してファイルサーバ間の通信を行うものである。クライアント計算機との通信はシステムバス８０に接続されたネットワーク通信手段により行う。本実施例のファイルサーバシステムにおいても、先に述べた各実施例で得られる効果と同様の効果が得られる。

【００３９】

【発明の効果】本発明によれば、ファイルアクセス負荷の少ないファイルサーバへアクセスを行なうことができる。しかも、ファイルとその複製ファイルを複数のファイルサーバに格納するため同一のディレクトリやファイルに対するクライアント計算機からのアクセス要求も複数のファイルサーバにその負荷状況に応じて分散することができる。したがって、ネットワーク上に複数のファイルサーバを並接し多数のクライアント計算機間でファイルの共有を行なうシステムで、複数のクライアント計算機が同一のディレクトリやファイルに同時にアクセスした場合でも、特定のファイルサーバへのアクセスの集中によるボトルネックの発生とそれに伴うスループットの低下を防ぐことができ、クライアント計算機からの高スループットのアクセスを実現できる。

【図面の簡単な説明】

【図１】本発明の実施例の全体構成を示すブロック図である。

【図２】実施例の主要部の詳細構成を示すブロック図である。

【図３】実施例のマスタファイルサーバのプログラム構成を示すブロック図である。

【図４】実施例のファイル管理プログラムの構成を示すブロック図である。

【図５】実施例におけるファイル属性テーブルの一例を示す概念図である。

【図６】実施例におけるファイル属性テーブルの別の例を示す概念図である。

【図７】実施例の他のファイルサーバのプログラム構成を示すブロック図である。

【図８】実施例におけるファイルアクセス処理の流れを示すフローチャートである。

【図９】実施例におけるにおけるファイル管理プログラムの処理の流れを示すフローチャートである。

【図１０】実施例におけるファイル格納形態の一例を示す概念図である。

【図１１】実施例におけるファイル格納形態の別の例を示す概念図である。

【図１２】本発明の別の実施例を示すブロック図である。

【図１３】本発明のさらに別の実施例を示すブロック図である。

【図１４】本発明のさらに別の実施例を示すブロック図である。

【図１５】本発明のさらに別の実施例を示すブロック図である。

【図１６】本発明のさらに別の実施例を示すブロック図である。

【図１７】本発明のさらに別の実施例を示すブロック図である。

【符号の説明】

１０、２０、３０…クライアント計算機、１１…アプリケーションプログラム、５０…ネットワーク、９０…ファイルサーバシステム、１００…マスタ・ファイルサーバ、１１０、１２０、１３０…ファイルサーバ、２００、２１０、２２０、２３０…通信制御手段、３００…遠隔ファイルアクセク処理手段、５００…ファイル管理手段、５０８…ファイル属性テーブル、５０９…負荷情報テーブル、６００、６１０、６２０、６３０…ファイルアクセス制御手段、７００、７１０、７２０、７３０…ファイル格納手段、９００…ＬＣＭＰネットワーク。

【図１】

(図１)

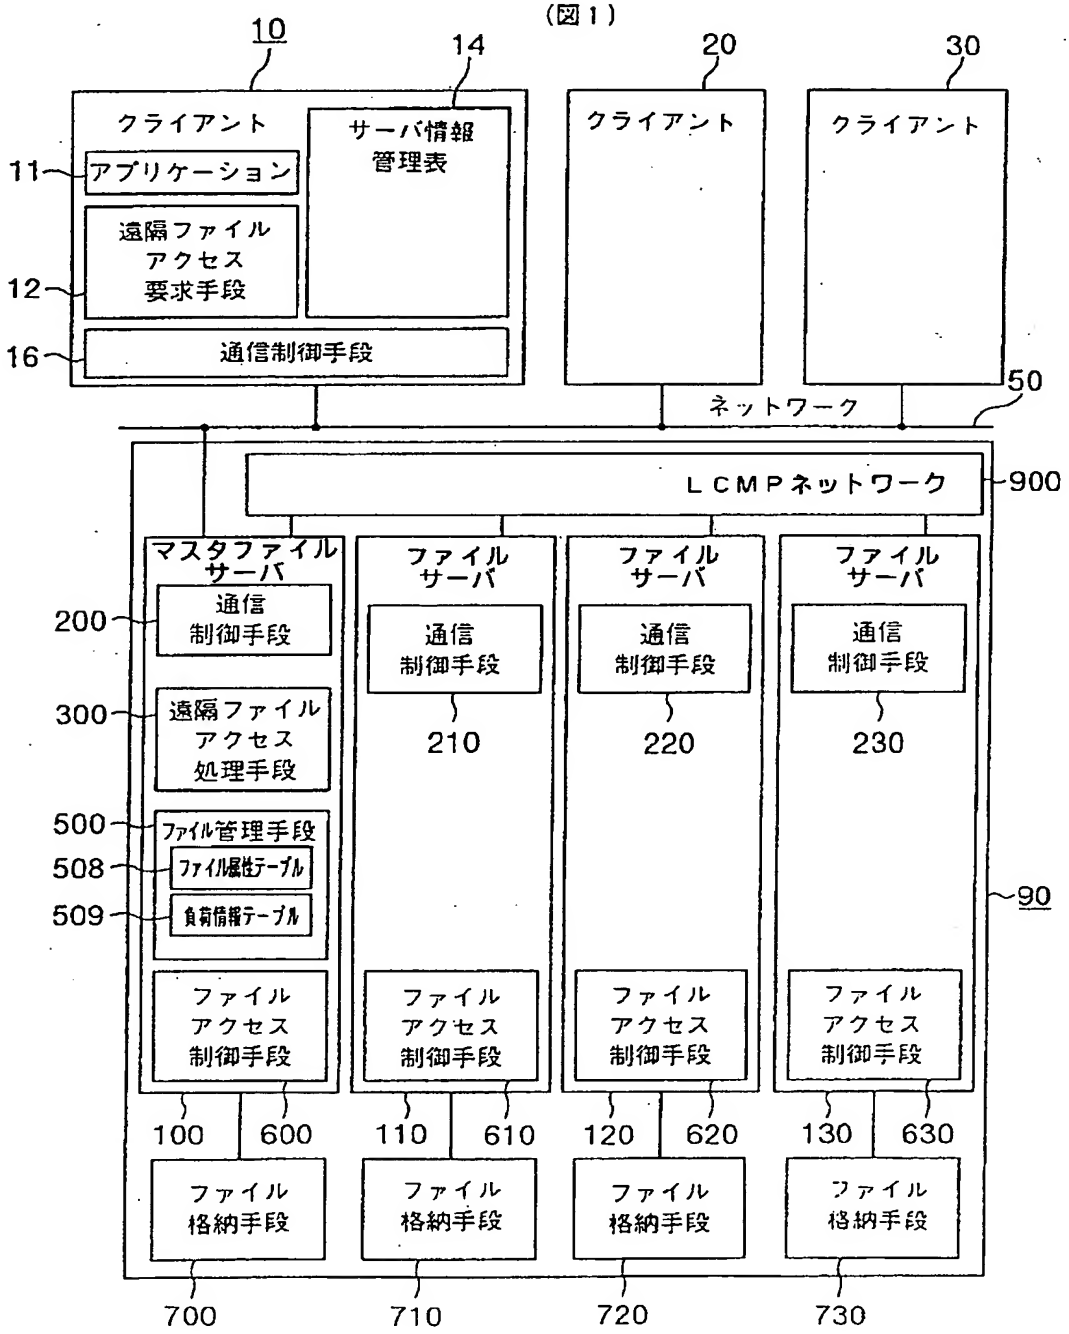

【図２】

（図２）

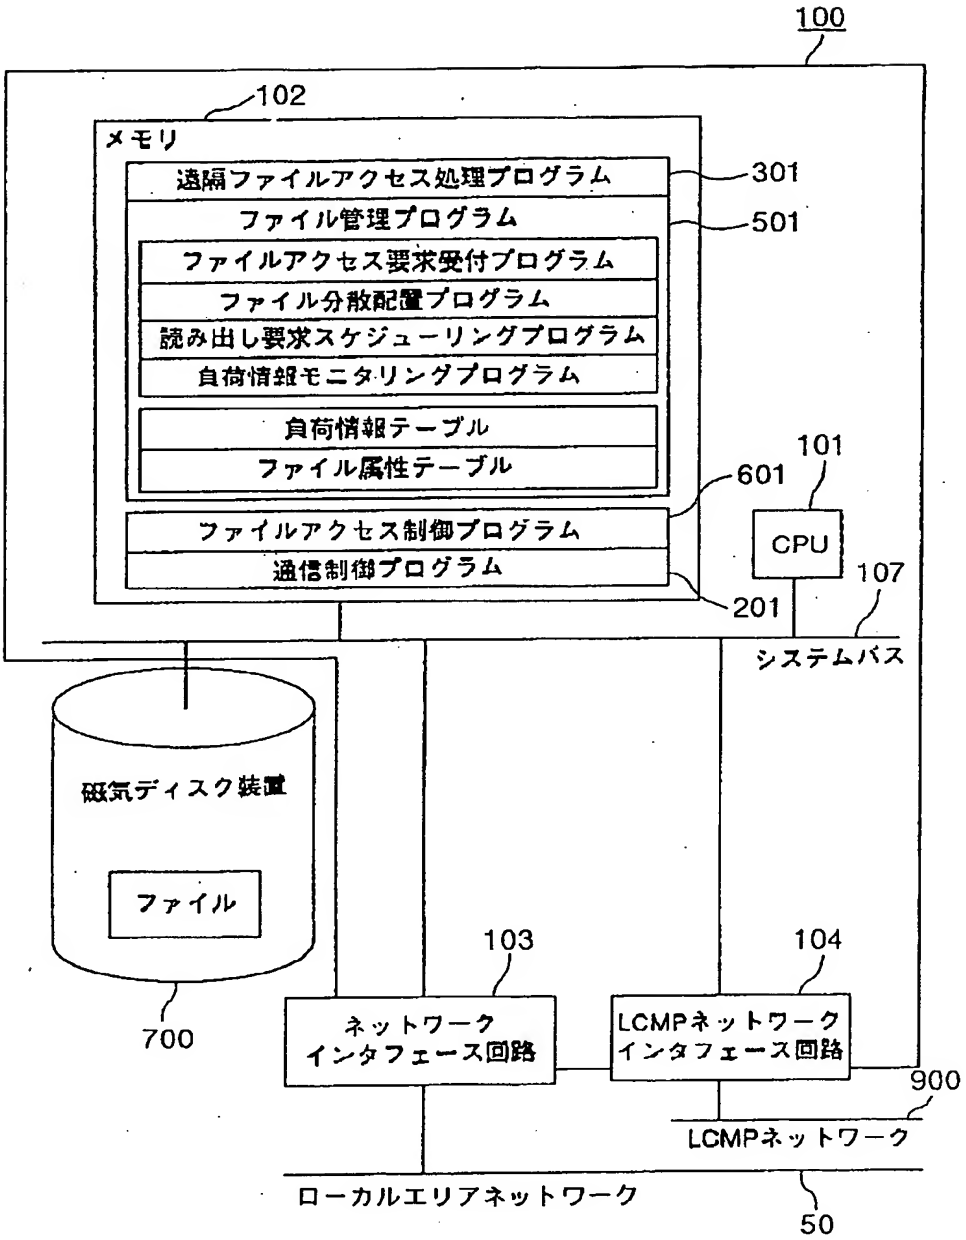
100
102
メモリ
遠隔ファイルアクセス処理プログラム
301
ファイル管理プログラム
501
ファイルアクセス要求受付プログラム
ファイル分散配置プログラム
読み出し要求スケジューリングプログラム
負荷情報モニタリングプログラム
負荷情報テーブル
ファイル属性テーブル
601
ファイルアクセス制御プログラム
通信制御プログラム
201
101
CPU
107
システムバス
磁気ディスク装置
ファイル
700
103
ネットワーク
インタフェース回路
104
LCMPネットワーク
インタフェース回路
900
LCMPネットワーク
ローカルエリアネットワーク
50

【図３】

(図３)

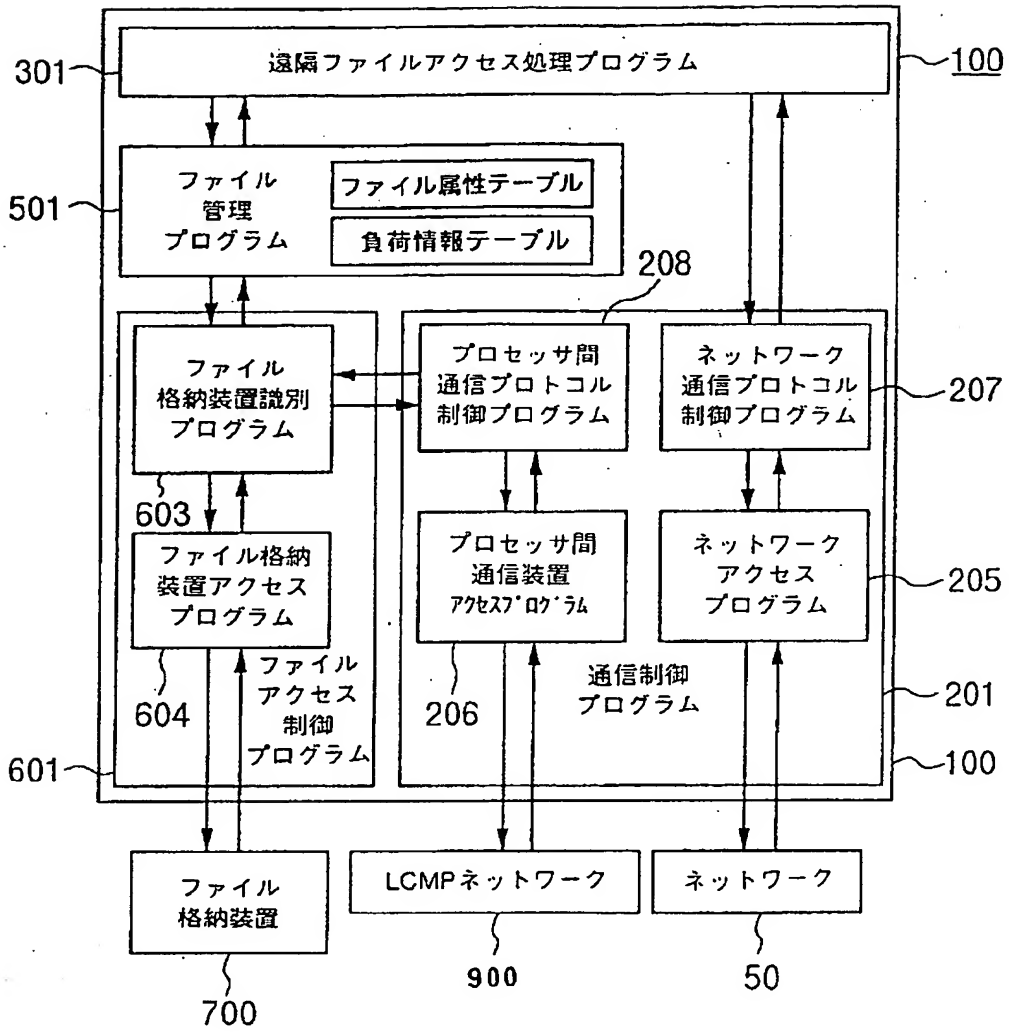
遠隔ファイルアクセス処理プログラム
301
100
ファイル
管理
プログラム
501
ファイル属性テーブル
負荷情報テーブル
208
ファイル
格納装置識別
プログラム
603
プロセッサ間
通信プロトコル
制御プログラム
ネットワーク
通信プロトコル
制御プログラム
207
ファイル格納
装置アクセス
プログラム
プロセッサ間
通信装置
アクセスプログラム
ネットワーク
アクセス
プログラム
205
604
ファイル
アクセス
制御
プログラム
206
通信制御
プログラム
201
601
100
ファイル
格納装置
LCMPネットワーク
ネットワーク
700
900
50

【図１５】

図 15

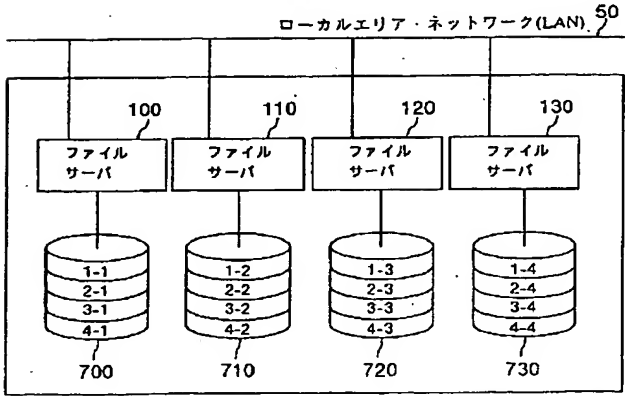
ローカルエリア・ネットワーク(LAN)
50
100
110
120
130
ファイル
サーバ
ファイル
サーバ
ファイル
サーバ
ファイル
サーバ
1-1
2-1
3-1
4-1
1-2
2-2
3-2
4-2
1-3
2-3
3-3
4-3
1-4
2-4
3-4
4-4
700
710
720
730

【図4】

図4

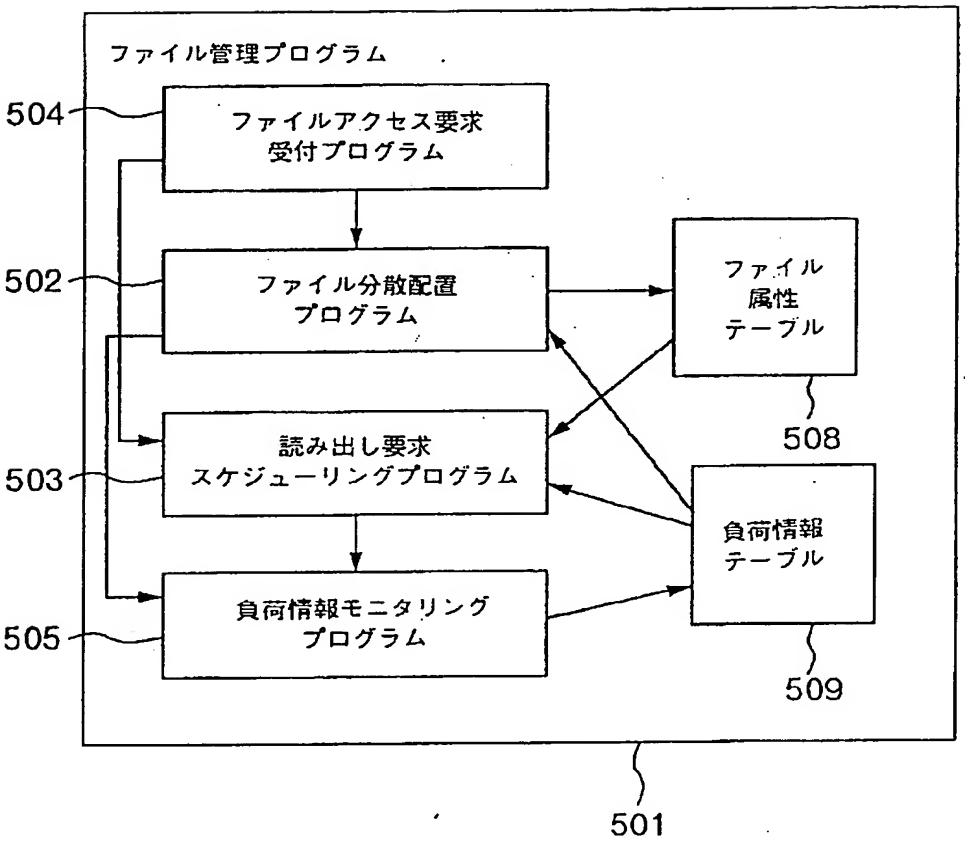
ファイル管理プログラム
504
ファイルアクセス要求
受付プログラム
502
ファイル分散配置
プログラム
ファイル
属性
テーブル
508
503
読み出し要求
スケジューリングプログラム
負荷情報
テーブル
505
負荷情報モニタリング
プログラム
509
501

【図10】

図10

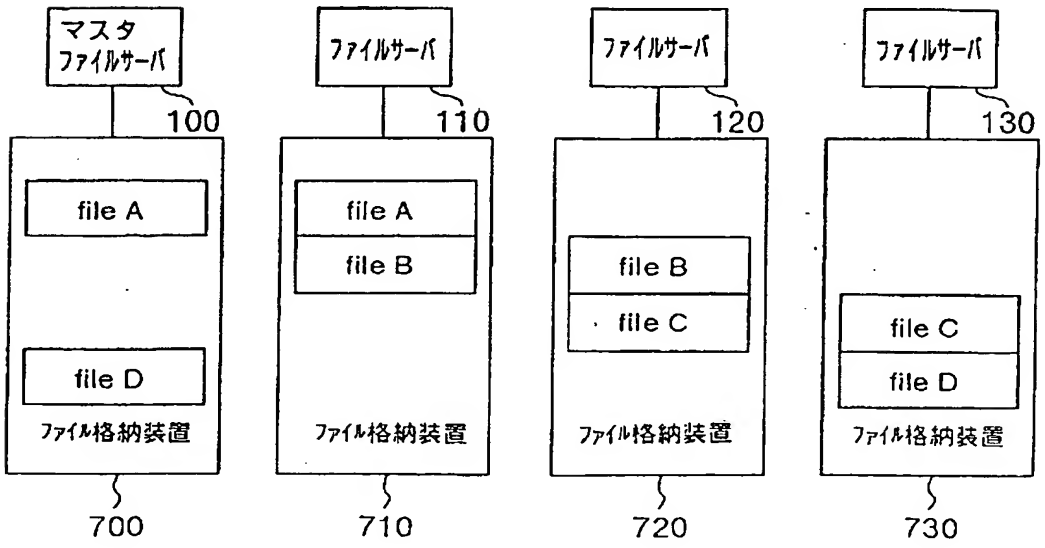
マスタ
ファイルサーバ
100
file A
file D
ファイル格納装置
700
ファイルサーバ
110
file A
file B
ファイル格納装置
710
ファイルサーバ
120
file B
file C
ファイル格納装置
720
ファイルサーバ
130
file C
file D
ファイル格納装置
730

【図5】

図5

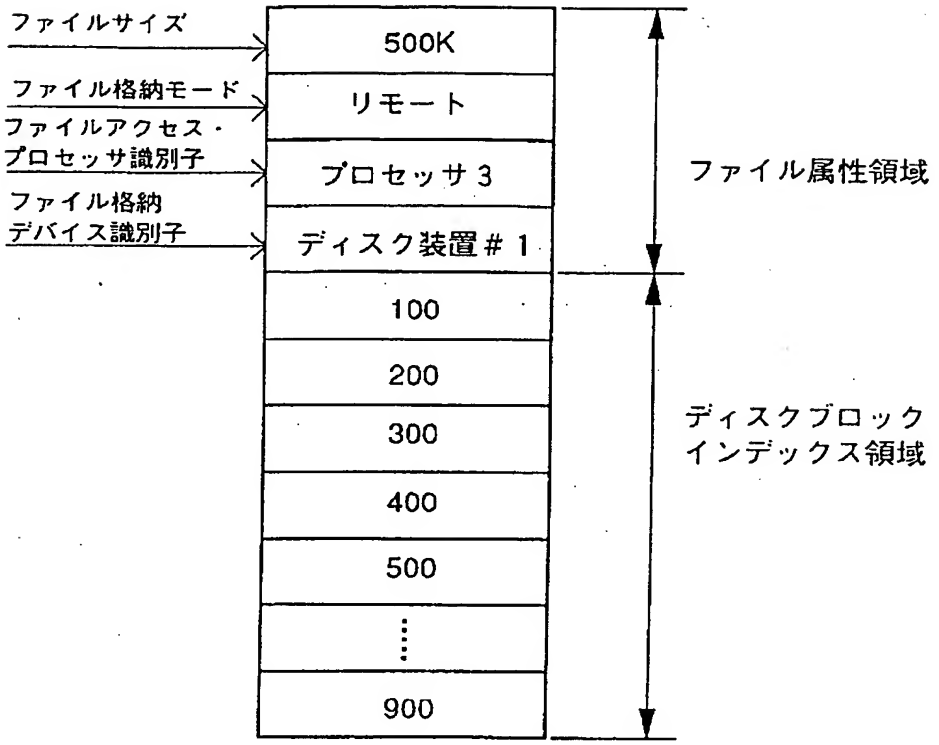
ファイルサイズ
ファイル格納モード
ファイルアクセス・
プロセッサ識別子
ファイル格納
デバイス識別子
500K
リモート
プロセッサ3
ディスク装置#1
ファイル属性領域
100
200
300
400
500
900
ディスクブロック
インデックス領域

【図11】

図11

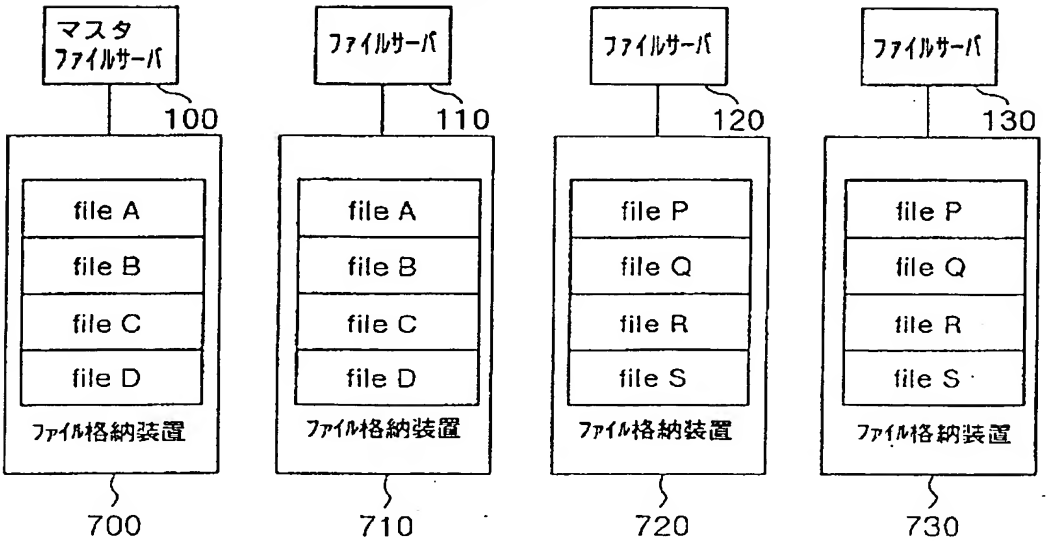
マスタ
ファイルサーバ
ファイルサーバ
ファイルサーバ
ファイルサーバ
100
110
120
130
file A
file B
file C
file D
file A
file B
file C
file D
file P
file Q
file R
file S
file P
file Q
file R
file S
ファイル格納装置
ファイル格納装置
ファイル格納装置
ファイル格納装置
700
710
720
730

【図６】

図６

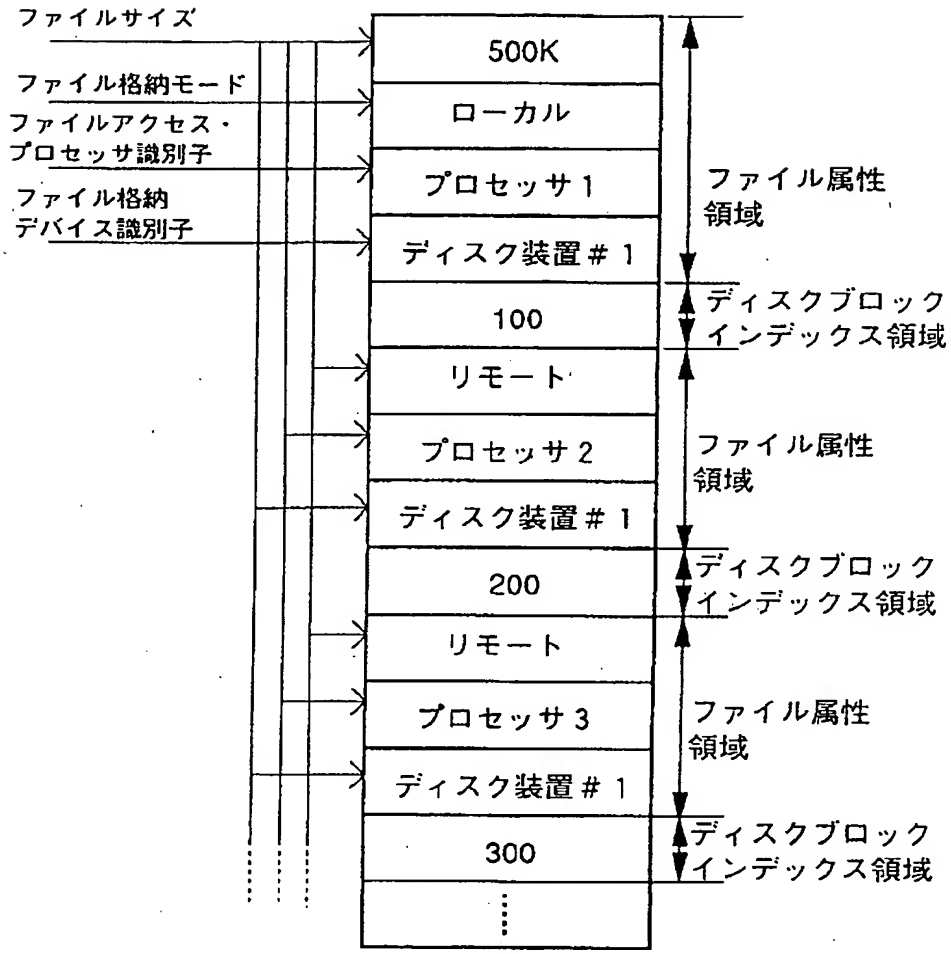
ファイルサイズ
ファイル格納モード
ファイルアクセス・
プロセッサ識別子
ファイル格納
デバイス識別子
500K
ローカル
プロセッサ１
ディスク装置＃１
100
リモート
プロセッサ２
ディスク装置＃１
200
リモート
プロセッサ３
ディスク装置＃１
300
ファイル属性
領域
ディスクブロック
インデックス領域
ファイル属性
領域
ディスクブロック
インデックス領域
ファイル属性
領域
ディスクブロック
インデックス領域

【図7】

図 7

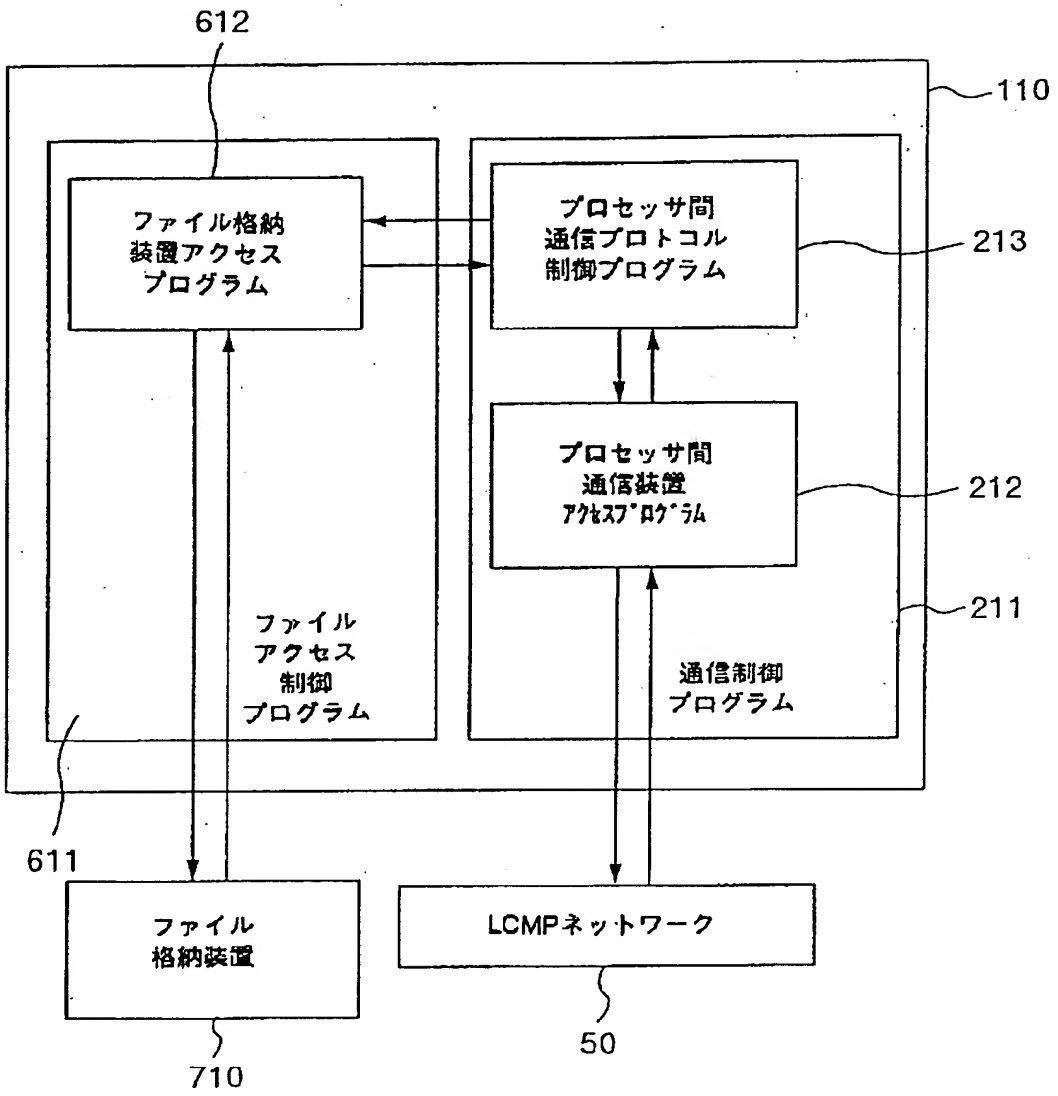
612
110
ファイル格納
装置アクセス
プログラム
プロセッサ間
通信プロトコル
制御プログラム
213
プロセッサ間
通信装置
ｱｸｾｽﾌﾟﾛｸﾞﾗﾑ
212
211
ファイル
アクセス
制御
プログラム
通信制御
プログラム
611
ファイル
格納装置
LCMPネットワーク
710
50

【図８】

図８

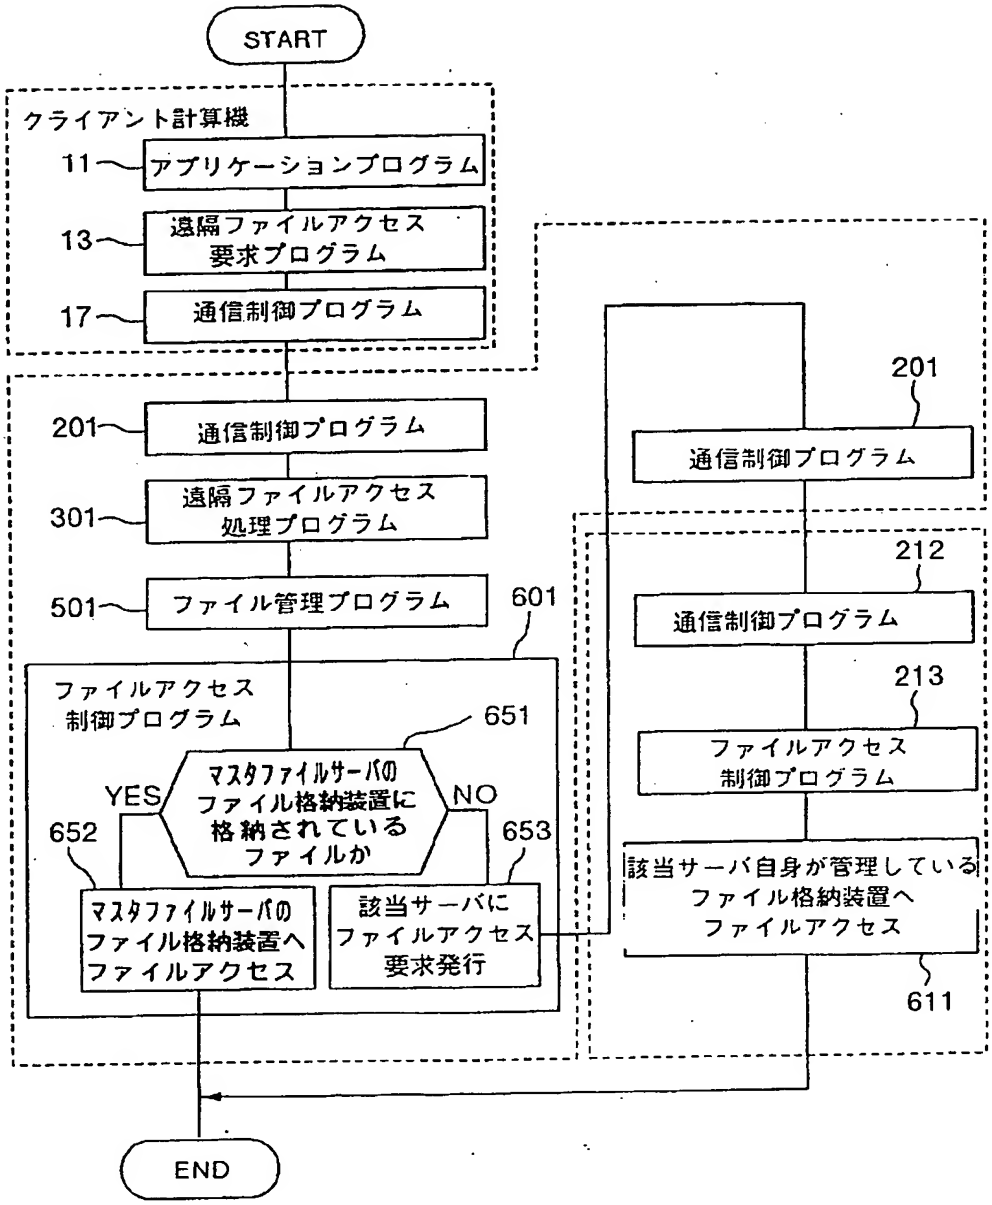
START
クライアント計算機
11
アプリケーションプログラム
13
遠隔ファイルアクセス
要求プログラム
17
通信制御プログラム
201
通信制御プログラム
301
遠隔ファイルアクセス
処理プログラム
501
ファイル管理プログラム
601
ファイルアクセス
制御プログラム
651
マスタファイルサーバの
ファイル格納装置に
格納されている
ファイルか
YES
NO
652
653
マスタファイルサーバの
ファイル格納装置へ
ファイルアクセス
該当サーバに
ファイルアクセス
要求発行
201
通信制御プログラム
212
通信制御プログラム
213
ファイルアクセス
制御プログラム
該当サーバ自身が管理している
ファイル格納装置へ
ファイルアクセス
611
END

【図9】

図 9

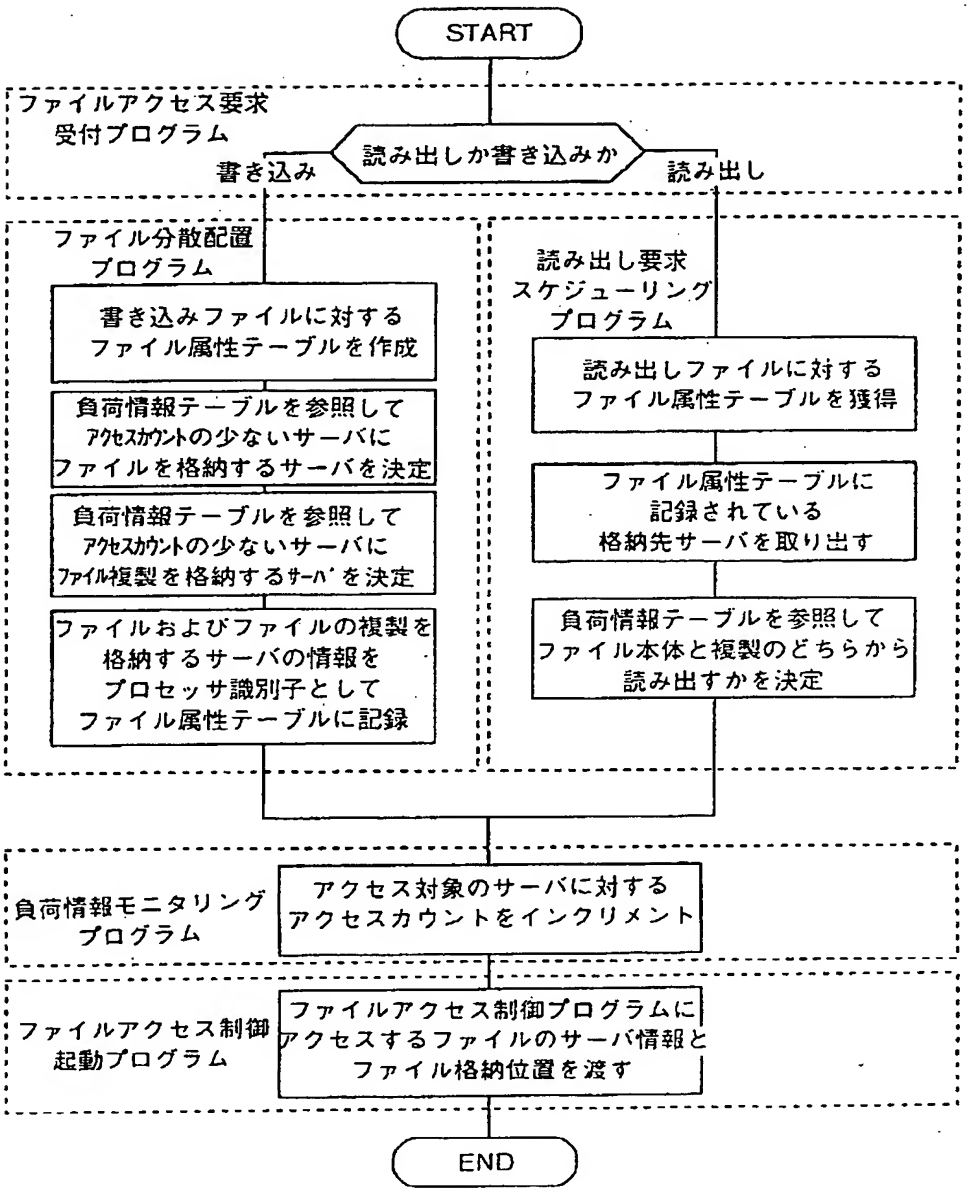
START
ファイルアクセス要求
受付プログラム
読み出しか書き込みか
書き込み
読み出し
ファイル分散配置
プログラム
書き込みファイルに対する
ファイル属性テーブルを作成
負荷情報テーブルを参照して
ｱｸｾｽｶｳﾝﾄの少ないサーバに
ファイルを格納するサーバを決定
負荷情報テーブルを参照して
ｱｸｾｽｶｳﾝﾄの少ないサーバに
ﾌｧｲﾙ複製を格納するｻｰﾊﾞを決定
ファイルおよびファイルの複製を
格納するサーバの情報を
プロセッサ識別子として
ファイル属性テーブルに記録
読み出し要求
スケジューリング
プログラム
読み出しファイルに対する
ファイル属性テーブルを獲得
ファイル属性テーブルに
記録されている
格納先サーバを取り出す
負荷情報テーブルを参照して
ファイル本体と複製のどちらから
読み出すかを決定
負荷情報モニタリング
プログラム
アクセス対象のサーバに対する
アクセスカウントをインクリメント
ファイルアクセス制御
起動プログラム
ファイルアクセス制御プログラムに
アクセスするファイルのサーバ情報と
ファイル格納位置を渡す
END

【図１２】

図 １２

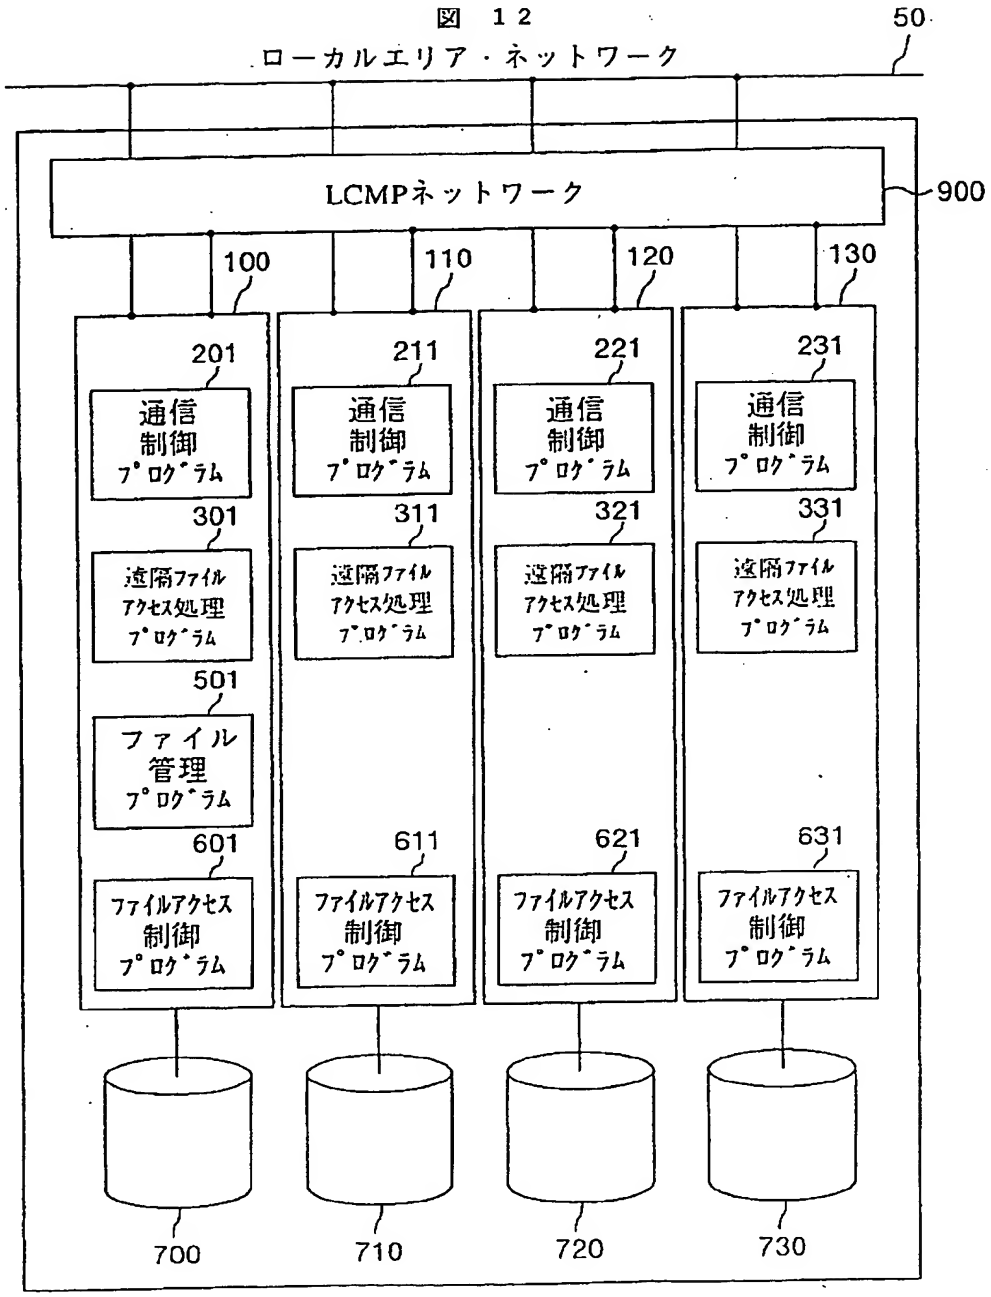
ローカルエリア・ネットワーク
50
LCMPネットワーク
900
100
110
120
130
201
211
221
231
通信制御プログラム
301
311
321
331
遠隔ファイルアクセス処理プログラム
501
ファイル管理プログラム
601
611
621
631
ファイルアクセス制御プログラム
700
710
720
730

【図１３】

図 13

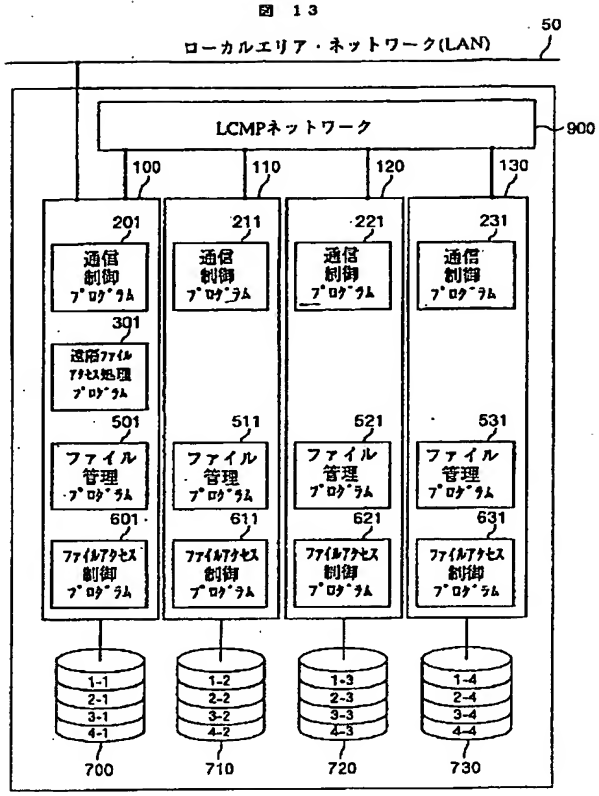

【図１４】

図 14

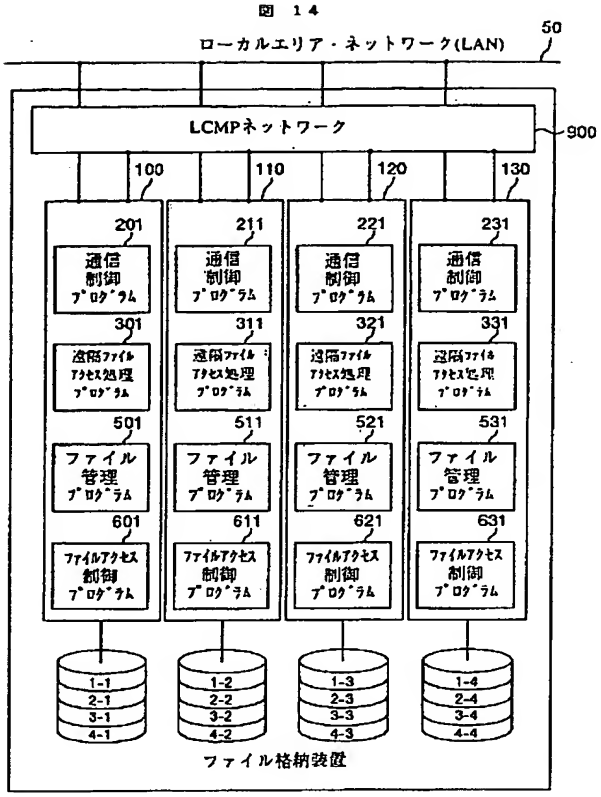

【図１６】

図 16

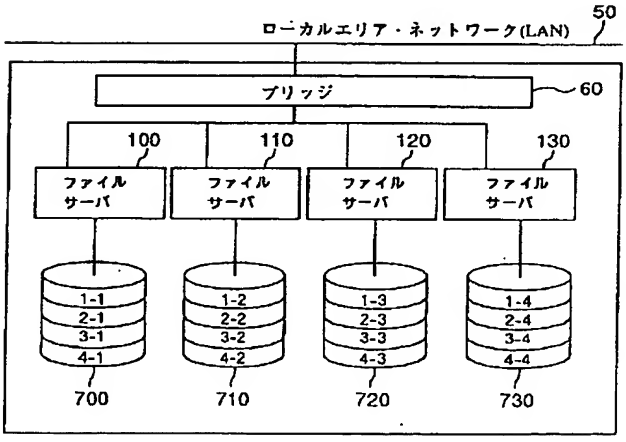

【図１７】

図 17

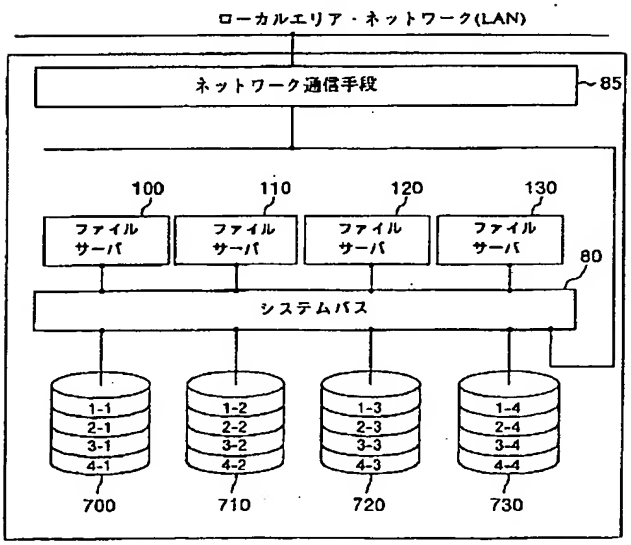

フロントページの続き

(72)発明者　山下　洋史
東京都国分寺市東恋ケ窪１丁目280番地
株式会社日立製作所中央研究所内
(72)発明者　多田　勝己
東京都国分寺市東恋ケ窪１丁目280番地
株式会社日立製作所中央研究所内
(72)発明者　川口　久光
東京都国分寺市東恋ケ窪１丁目280番地
株式会社日立製作所中央研究所内
(72)発明者　加藤　寛次
東京都国分寺市東恋ケ窪１丁目280番地
株式会社日立製作所中央研究所内
(72)発明者　鬼頭　昭
神奈川県横浜市戸塚区戸塚町5030番地　株式会社日立製作所ソフトウェア開発本部内
(72)発明者　山田　秀則
神奈川県秦野市堀山下１番地　日立コンピュータエンジニアリング株式会社内

PATENT ABSTRACTS OF JAPAN

(11)Publication number : 2002-163140
(43)Date of publication of application : 07.06.2002

(51)Int.Cl. G06F 12/00
G06F 13/10

(21)Application number : 2000-359810
(22)Date of filing : 27.11.2000

(71)Applicant : FUJITSU LTD
(72)Inventor : OE KAZUICHI
NISHIKAWA KATSUHIKO

(54) STORAGE SYSTEM

(57)Abstract:
PROBLEM TO BE SOLVED: To provide a storage system having a scalability capable of fully coping with the band expansion of a network at a low cost.
SOLUTION: This storage system is provided with a storage device 17 capable of storing file data, a plurality of file servers 12-1 through 12-n performing file processes in response to requests on file data to the storage device 17, a file server management node 11 managing the transfer processes of the file requests received from clients 2 via an external network 3 to the file servers 12-i (i=1 through n) and the response processes to the clients 2 for the file requests, and the internal network 14 communicatably connecting the storage device 17, the file servers 12-i, and the file server management node 11 together.

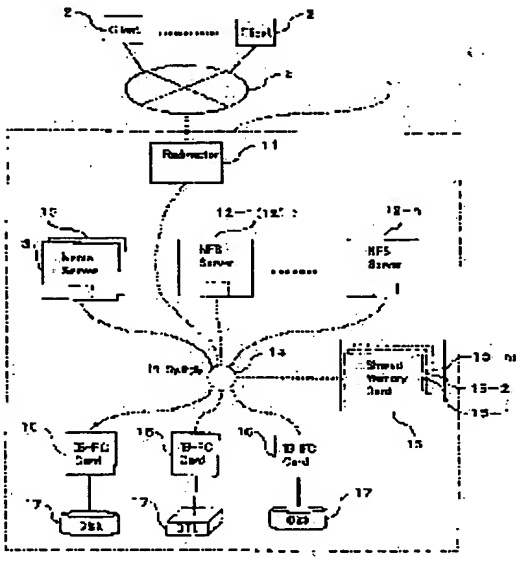

LEGAL STATUS

[Date of request for examination]

[Date of sending the examiner's decision of rejection]

[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]

[Date of final disposal for application]

[Patent number]

[Date of registration]

[Number of appeal against examiner's decision of rejection]

[Date of requesting appeal against examiner's decision of rejection]

[Date of extinction of right]

* NOTICES *

1. This document has been translated by computer.So the translation may not reflect the original precisely.
2. **** shows the word which can not be translated.
3.In the drawings, any words are not translated.

CLAIMS

[Claim(s)]
[Claim 1] The storage which can memorize file data, and two or more file servers which perform file processing according to the request about this file data to this storage, The transfer processing to this file server of the request received from a client through an external network, The file server management node which carries out unitary management of the response processing to this client to this request, The storage system characterized by having offered the internal network which interconnects this storage, this file server, and this file server management node possible [communication], and being constituted.
[Claim 2] The storage system according to claim 1 characterized by connecting the name server which carries out unitary management of the file data name which this file server treats to this internal network.
[Claim 3] The storage system according to claim 1 characterized by connecting the shared memory with accessible this file server management node and this file server to this internal network.
[Claim 4] The storage system according to claim 2 characterized by connecting the shared memory with accessible this file server management node, this file server, and this name server to this internal network.
[Claim 5] A storage system given in any 1 term of claims 1-4 characterized by having offered the request analysis section in which this file server management node analyzes the content of this request, and the request transfer section which transmits this request to a specific file server according to the analysis result of this request analysis section.

[Translation done.]

* NOTICES *

1.This document has been translated by computer. So the translation may not reflect the original precisely.
2.**** shows the word which can not be translated.
3.In the drawings, any words are not translated.

DETAILED DESCRIPTION

[Detailed Description of the Invention]
[0001]
[The technical field to which invention belongs] this invention relates to the storage system which enables sharing of file data by two or more clients by connecting with a desired network about a storage system.
[0002]
[Description of the Prior Art] As conventional technique of realizing sharing (only henceforth "file sharing") of the file data between two or more nodes (client) on a network For example, as typically shown in drawing 16 , a file server 200 is built on the desired networks 100, such as LAN (Local Area Network), using a Network File System (NFS:Network File System). A secondary storage 400 is connected to this file server 200 through the interfaces 300, such as SCSI (Small Computer System Interface; -- generally called "SCSI"). The method of realizing file sharing between two or more clients 500 in this secondary storage 400 is learned well.
[0003] However, the following technical problems occur by this method.
** Special skill is required to build and maintain a file server (maintenance).
** Extension (capacity, access performance) of a file server is not easy. Even if extensible, maintenance cost will increase by a file server being divided into plurality etc.
[0004] ** Special skill is required for the system construction and maintenance (maintenance) offered at the time of failure, and the costs for it also start.
NAS (Network Attached Storage) is proposed as a method of solving these technical problems in recent years. It is the system which the portion (refer to the dashed line frame in drawing 16) which consists of an above-mentioned file server 200 and an above-mentioned secondary storage 400 is equivalent to what was beforehand built as one storage system, connects with a network 100, and this NAS only performs an easy setup, and can realize file sharing, and special skill is unnecessary to construction and maintenance of a system (maintenance).
[0005]
[Problem(s) to be Solved by the Invention] However, also in such NAS, the technical problem that the scalability which can fully respond to band expansion (it will be about 10Gbps after (1Gbps and several years) in the present condition) of LAN which is progressing quickly now by the low cost is not obtained remains. That is, when it is going to correspond to band expansion of the network of a connection place, also in NAS, simply, an internal file server and an internal secondary storage will be extended, consequently a file server will be divided into plurality, and the secondary storage which each manages will also be divided.
[0006] That is, an above-mentioned file server 200 and an above-mentioned secondary storage 400 will be arranged in parallel and (independent) prepared. For this reason, it will be necessary to maintain a file server separately (maintenance), and maintenance cost will increase after all. It was originated in view of such a technical problem, and this invention aims at offering a storage system with the scalability which can fully respond by the low cost to band expansion of a network.
[0007]
[Means for Solving the Problem] In order to attain the above-mentioned purpose, the storage system (claim 1) of this invention The storage which can memorize file data, and two or more file servers which perform file processing according to the request to this storage, The transfer processing to the above-mentioned file server of the request received from a client through an external network, It is characterized by having offered the internal network which interconnects the file server management node which carries out unitary management of the response processing to the client to the request, and storage, an above-mentioned file server and an above-mentioned file server management node possible [communication], and being constituted.
[0008] Here, the name server which carries out unitary management of the file data name which the above-mentioned file server treats may be connected to the above-mentioned internal network, and the shared memory with accessible above-mentioned file server management node and above-mentioned file server may be connected to it (claim 3). (claim 2) In addition, when the above-mentioned name server exists, in addition to an above-mentioned file server management node and an above-mentioned file server, this name server can also be accessed at the above-mentioned shared memory (claim 4).
[0009] Moreover, it is desirable for the above-mentioned file server management node to offer the request analysis section which analyzes the content of the above-mentioned request, and the request transfer section which transmits this request to a specific file server according to the analysis result of this request analysis section, and to be constituted (claim 5).
[0010]
[Embodiments of the Invention] Hereafter, the gestalt of operation of this invention is explained with reference to a drawing.
(A) The explanatory drawing 1 of 1 operation gestalt is a block diagram showing the storage structure of a system (storage architecture) as 1 operation gestalt of this invention. The storage system 1 (only henceforth "a system 1") shown in this drawing 1 It is for realizing file sharing among two or more clients 2 connected to the external network (for example, Gigabit Ethernet (registered trademark)) 3. A redirector (Redirector) 11, two or more NFS servers (file server) 12-1 - 12-n, a name server 13, a shared memory (Shared Memory) 15, the IB-FC card 16, and a secondary storage 17 [a disk unit, a tape unit (DTL), etc.] It has offered. It has each of these components 11, 12-i, and the composition that 13, 15, 16, and 17 were mutually connected through the high-speed (interior) network [in FINI band (Infiniband)] switch 14 which is a 4-10Gbps (gigabit/second) grade.
[0011] Thus, if NFS server 12-i and a secondary storage 17 are connected to the internal network 14 if needed by taking the gestalt (clustering) which connects each components inside a system (a redirector 11, NFS server 12-i, a name server 13, secondary storage 17, etc.) in the internal network 14, it can extend easily, and the expandability (capacity, access performance, etc.) according to the transmission speed of the external network 3 etc. improves sharply.
[0012] Here, the above-mentioned redirector (file server management node) 11 is for carrying out unitary (concentration) management of the transfer processing to NFS server 12-i (i=1-n) of the various request messages (only henceforth a "request") received from the arbitrary clients 2 through the external network 3, and the response processing to the client 2 of the request origin to the request. That is, there is no need of maintaining them separately like before by existence of this redirector 11 though NFS server 12-i and a secondary storage 17 are extended like ****.

[0013] In addition, the above-mentioned "request" means the demand about the file data (only henceforth a "file") memorized by the secondary storage 17, for example, has the file manipulation demands (writing / updating / read-out) (file access request) to the substance of file data, meta-information access of other refer to the file name, etc. Moreover, from each client 2, only IP (Internet Protocol) address given to this redirector 11 can be referred to fundamentally. That is, from each client 2, this system 1 appears as one file server.
[0014] That a function which was mentioned above should be realized and to this redirector 11 For example, Gigabit Ethernet card 11a which equips the interface for external network 3 as shown in drawing 2 , In FINI band card 11b which equips the interface for the interior of a system (internal network), Network processor 11c for carrying out centralized control of the operation of

selves (redirector 11) including each of these cards 11a and 11b, Memory (primary storage) 11d for memorizing required software (program) and various data, when this network processor 11c operates etc. is mounted.
[0015] In addition, network processor 11c is connected with these components 11a-11d possible [two way communication] through PCI (Peripheral Component Interconnect) bus 11e. The above-mentioned network processor 11c here Transmission and reception (protocol conversion etc. is included) of the reply (response) message to the request sent and received between the internal network 14 and the external network 3, or its request etc., The analysis of the request (protocol) received from a client 2, the determination of the access file name based on the analysis result, the decision of destination NFS server 12-i of a receive request, etc. can be made, and the following control is also attained with this operation gestalt.
[0016] Namely, the request from a client 2 is analyzed, and it can control, or it can be controlled [the request about the same file can be assigned to the same NFS server 12-i, and] now so that file access competition does not occur between the NFS servers 12-i so that a request is uniformly transmitted to each file server 12-i (to for example, NFS server 12-i with a light load).
[0017] For this reason, if its attention is paid to the function of the important section, the following function parts are mounted in this network processor 11c.
(1) As the request analysis section 111 which analyzes the content of the request from a client 2 ****** (2) Transfer history of the request of the past by the function (3) request transfer section 112 as the request transfer section 112 which transmits a receive request to specific NFS server 12-i according to the analysis result of this request analysis section 111 (for example) By performing in the background the function (4) NFS server load surveillance demon (daemon) 115 as the transfer history Records Department 113 which records at memory 11d the function as the load Monitoring Department 114 which supervises periodically the loaded condition of each NFS server 12-i -- by this, the above-mentioned request transfer section 112 Based on the transfer history by the above-mentioned transfer history Records Department 113, transmit the request to the file of the same file name to same NFS server 12-i, or It becomes possible to transmit a receive request to low NFS12-i of a load based on the load surveillance result by the NFS server load surveillance demon 115 (load Monitoring Department 114).
[0018] Therefore, since a request can be uniformly transmitted to each NFS server 12-i while processing speed improves sharply, what a load concentrates on a part of NFS server 12-i, and causes an obstacle can be prevented certainly, and reliability improves it sharply. In addition, this network processor 11c carries out the cache of the reply message for example, to meta-information access to cache memory 11f (memory 11d is sufficient) of the interior (refer to drawing 3). When the request about meta-information access is received from a client 2, it is cache memory 11f () first. or if memory 11d is checked and hit, a reply message is created, and it will return to a client 2 side as it is (refer to drawing 4) -- (without transmitting to NFS server 12-i or a name server 13) it can also be made like
[0019] This structure is applicable not only about meta-information but file data. However, it is better to select file data with high access frequency by network processor 11c, and to be made to carry out the cache only of the file data to cache memory 11f (or memory 11d), since required memory space increased when it was made to carry out the cache of all the file data in this case.
[0020] That is, the above-mentioned cache memory 11f () Or the function as the cache section which carries out the cache of the reply message to the client 2 about specific file data with high request frequency is also achieved memory 11d. Network processor 11c in this case is it cache memory 11f () that it is a thing about the file with the same new request. Or it will also have the function as the response section 116 (refer to drawing 2) which returns the reply message which carried out the cache to memory 11d to a client 2.
[0021] Thus, if a response is returned by the redirector 11 about the information (meta-information, file data) that access frequency is high, without carrying out a cache by the redirector 11 side, and transmitting a request to NFS server 12-i, the speed of response to the client 2 to the information that access frequency is high will improve sharply, and the processing speed and the throughput as this system 1 will improve by leaps and bounds.

[0022] Next, the above-mentioned NFS server 12-i can access file processing (writing / updating / read-out) according to the request transmitted from the redirector 11 at internal network (internal network switch) 14 course at a secondary storage 17, can be carried out, or can generate the reply message for sending the file-processing result as a response to the client 2 of a requesting agency, and can be transmitted to a redirector 11, respectively.
[0023] Each NFS server 12-i in addition, in hardware For example, as shown in drawing 5 Offer interface card (IB-IF) 12c which equips interfaces (protocol conversion etc.) with CPU(Central Processing Unit) 12a, memory (primary storage) 12b, and the internal network 14, and it is constituted. By CPU12a's reading the NFS server software (program) memorized by memory 12b, and operating, the function as NFS server 12-i mentioned above is realized.
[0024] Now, un-arranging [of being as becoming the same management file name by NFS server 12-i which is different conversely in spite of being different file data substance **** /, and] may arise, and file access competition may arise between the NFS servers 12-i. / management file names differing by NFS server 12-i from which it differs here although such NFS server 12-i is the same file data substance when a file name is managed uniquely, respectively
[0025] The above-mentioned name server 13 solves such un-arranging. That is, in this name server 13, by carrying out unitary management of the meta-information access from NFS server 12-i, management file name space in all NFS server 12-i is set to one, and the file access competition between the NFS servers 12-i is avoided. Therefore, the reliability of file sharing by this system 1 will improve sharply by offering this name server 13.
[0026] in addition, it is shown in drawing 1 -- as -- this name server 13 -- heterologies (down), such as failure, -- offering -- present -- business and the object for reserves exist moreover, in hardware also about these name servers 13 Interface card 13c which equips an interface with the same composition as NFS server 12-i (refer to drawing 5), i.e., CPU13a, memory (primary storage) 13b, and the internal network 14 is mounted. The function as a name server 13 mentioned above is realized by CPU13a's reading the name server software (program) memorized by memory 13b also in this case, and operating.
[0027] Next, the redirector 11 of the above [the above-mentioned shared memory 15], NFS server 12-i, and a name server 13 are accessible memory through the internal network 14, respectively. for example, certain NFS server 12-i -- or -- present, when the name server 13 of business is downed (at the time of obstacle generating) the NFS server 12-i -- or -- present -- the information for taking over processing of the name server 13 of business to the name server 13 other NFS server 12-k (it being k!=i at k= 1 - n), or for reserves -- (Following and taking over information) etc. -- server 12-i and 13 -- it is held independently at memory card (Shared Memory Card) 15-1 - 15-m (m is the natural number) (refer to drawing 6 and drawing 8) (backup)
[0028] That is, each above-mentioned NFS server 12-i (CPU12a) or the name server 13 (CPU13a) will have the function as the taking over information Records Department 121 (131) (refer to drawing 5) which succeeds information required to offer at the time of a heterology and take over processing to the name server 13 other NFS server 12-i or for reserves, and is recorded on a shared memory 15 as information.
[0029] in addition, the down of NFS server 12-i is typically shown in drawing 6 -- as -- present -- the name server 13 (CPU13a) of business performs the NFS server surveillance demon 132 in the background -- supervising -- present -- as typically shown in drawing 8 , the down of the name server 13 of business is supervised because the name server 13 (CPU13a) for reserves performs the name server surveillance demon 133 in the background
[0030] And as typically shown in drawing 7 , when the down of NFS server 12-i is detected (Step S1) As opposed to NFS server 12-k (for example, NFS server 12-k with a light load) other than NFS server 12-i to which the name server 13 (CPU13a) of business was downed present -- While directing to succeed processing of downed NFS server 12-i, the down of NFS server 12-i is notified to a redirector 11 (Step S2).
[0031] NFS server 12-k (CPU12a) which received taking over directions accesses a shared memory 15 through the internal network 14 by this, and processing of NFS server 12-i which read the taking over information backed up there and was downed is succeeded (Step S3). On

the other hand, a redirector 11 (network processor 11c) is made not to transmit the request by the request transfer section 112 by receiving the above-mentioned notice from a name server 13 to downed NFS server 12-i at this time.
[0032] That is, the name server 13 (CPU13a) in this case The malfunction detection section 134 (refer to drawing 6) which detects the heterology of NFS server 12-i, If the heterology of NFS server 12-i is detected in this malfunction detection section 134 It will have the function as the taking over directions section 135 (refer to drawing 6) which gives [succeeding the processing of NFS server 12-i which carried out the heterology to other NFS server 12-k other than the NFS server 12-i based on the taking over information on a shared memory 15, and] taking over directions.
[0033] Thus, with this operation gestalt, since the name server 13 other NFS server 12-k and for reserves can succeed processing even if NFS server 12-i and a name server 13 are downed, file processing normal as a storage system 1 can be continued, and obstacle-proof nature improves sharply. In addition, although this example is explanation about redundant-izing of NFS server 12-i or a name server 13, of course, it is also possible to redundancy-ize a redirector 11 similarly. moreover -- present -- you may make it take over to either of the NFS server 12-i depending on the case about the taking over at the time of the name server 13 down of business

[0034] Next, the redirector 11 at the time of the request transfer to NFS server 12-i from the redirector 11 mentioned above and the concrete processing by NFS server 12-i are explained. A redirector 11 will analyze the file access request in the request analysis section 111, if the file access request for writing in a certain file data from a client 2 is received.
[0035] In addition, as shown in drawing 12 , the above-mentioned "file access request" has the header unit 21 which consists of physical-layer header (Phy Header) 21a, IP header (Internet Protocol Header) 21b, TCP header (Transmission Control Protocol Header) 21c, and NFS header 21d etc., and the real file data section 22 in which the substance (real file data) of file data which should actually be written in a secondary storage 17 was stored, and changes.
[0036] And the request analysis section 111 asks for the boundary of the position where the real file data under above-mentioned file access request starts, i.e., a header unit 21 and the real file data section 22, as header offset value [number-of-bits ("a") etc. 23 from boundary information;, for example, a head,], as typically shown in drawing 9 . The boundary information 23 searched for is notified to the request transfer section 112, and the request transfer section 112 appends the boundary information 23 notified to the above-mentioned file access request (addition), and sends it to NFS server 12-i of the destination.
[0037] That is, as shown in drawing 2 , the above-mentioned request analysis section 111 The function as header offset value analysis section 111a to calculate the header offset value 23 which analyzes the received file access request and expresses the boundary position of the header unit 21 of the file access request, and the real file data section 22, It will have the function as header offset pricing Kabe 111b which adds the header offset value 23 acquired by this header offset value analysis section 111a to the file access request to which it is transmitted to NFS server 12-i.
[0038] Then, in the NFS server 12-i side, it is based on the header offset value 23 added by the redirector 11 side like ****. The NIC (Network Interface Card) driver (network driver) 122 The real file data section 22 and the other field The start address of (a header unit 21) can be assigned to the page boundary [the page boundary (another field); buffer (mbuf) 123,124] of the message treated within the kernel of a high order layer (NFS processing layer) (kernel high order layer), respectively (refer to drawing 10).
[0039] When are done in this way and a file access request reaches the file system section 125 of a kernel high order layer as typically shown, for example in drawing 11 , it becomes possible to move data to the file system buffer 126 only by changing the start address (pointer) of the real file data section 22 for the pointer to the file system buffer 126, without generating a copy of data (map change) (the zero copy in a kernel is realized). Therefore, DMA (Direct Memory Access) can also be performed at high speed, and can improve sharply the processing speed and the throughput of NFS server 12-i.

[0040] In addition, although making it ask by the NIC driver 122 side is also thought of, the boundary of a header unit 21 and the real file data section 22 In this case, since the amount of processings (header analysis) of the NIC driver 122 increases (the NIC driver 122 usually performs only analysis of physical-layer header 21a), The direction which asked for the boundary by the redirector 11 side which has the analysis feature (request analysis section 111) of a header unit 21 from the first as mentioned above The kernel zero copy in a high order layer (NFS processing layer) can be realized, without increasing the throughput in a NIC driver layer (** which does not cause a throughput fall).
[0041] According to the storage system 1 of this operation gestalt, as mentioned above, to the system 1 interior By having formed a redirector 11, two or more NFS server 12-i, the name server 13, the shared memory 15, and the secondary storage 17, and having made these the composition connected in the high-speed internal network 14 Since NFS server 12-i and a secondary storage 17 can be extended easily if needed and it moreover is not necessary to maintain NFS server 12-i separately (maintenance) The performance (for example, it can respond to 10GbpsLAN) and capacity scalability which can fully respond by the low cost to band expansion of the external network 3 are securable.
[0042] Especially with the operation gestalt mentioned above, a redirector 11 so that processing may be uniformly assigned to each NFS server 12-i according to the load of each NFS server 12-i control or Assign the processing to the request about the same file to the same NFS12-i, or Since it answers by the reply message which carried out the cache by the redirector [not NFS server 12-i but] 11 side to the request about the high file of access frequency The processing speed and performance are improving by leaps and bounds, and the performance and the capacity scalability which can certainly respond are realized to 10GbpsLAN.
[0043] (B) NFS server 12-i with a larger capacity of memory 12b than other NFS server 12-i is arranged as cache server 12' (refer to drawing 1), and you may make it the file access in this cache server 12' return a response only by the R/W to memory 12b fundamentally in the system 1 in which the 1st modification carried out explanation **** at a client 2 side.
[0044] And about the high file of the access frequency whose request frequency within a fixed period is more than the number of times of predetermined (threshold), the cache is carried out to memory 12b of cache server 12', and it is made for cache server 12' to answer. Specifically, first, the access frequency of each file is supervised by the redirector 11 side, and about access to a file with access frequency higher than a certain threshold, directions are given to a name server 13, NFS server 12-i, and cache server 12' from redirector 12-i so that it may process by cache server 12-i.
[0045] That is, at this time, a redirector 11 (request transfer section 112) will transmit the request about the high file of access frequency to cache server 12'. Thereby, since access to the high file of access frequency is processed within cache server 12', without accessing a secondary storage 17, it contributes to the large improvement in the processing speed as a storage system 1, and a throughput greatly.
[0046] on the other hand, if the access frequency to the high file of the above-mentioned access frequency falls, a redirector 11 directs to assign suitable (for example, a load -- light) NFS server 12-i, and to shift processing to a name server 13, NFS server 12-i, and cache server 12' (if the access frequency to the file by which the cache is carried out to memory 12b of cache server 12' becomes below the number of times of predetermined)
[0047] That is, a redirector 11 (request transfer section 112) changes the destination of a request into NFS server 12-i other than cache server 12' in this case. While it is avoided that the cache of the file from which access frequency has fallen continues being forever carried out to cache server 12' by this, consequently it can cut down memory space required for cache server 12', it can give a margin to processing by cache server 12', and can improve the throughput.
[0048] (C) It is also possible to enable it to access a secondary storage 17 also from the external node 19 by [which is explanation of the 2nd modification] connecting the above-mentioned secondary storage 17 with a name server 13 and NFS server 12-i by FC switch 18 course (a secondary-storage network being built), and connecting the FC switch 18 and the

external node 19, as shown in drawing 13 . However, the file system operated by the external node 19 in this case needs to be the same as the file system in the storage system 1.
[0049] Although a certain mediation control is needed about access from the external node 19 by doing in this way in order to avoid the access competition with NFS server 12-i of the system 1 interior, access to the file in this storage system 1 from the external node 19 is attained. Since the management file name in a system 1 will be followed also about access from the external node 19 if access to a name server 13 from the external node 19 is permitted as it corrects, for example, is shown in drawing 14 , the file access from the external node 19 can be performed without needing the above-mentioned mediation control. In addition, although it is the case where access to the name server 13 in internal network 14 course is permitted, in this drawing 14 , you may make it, permit access by secondary-storage network (FC switch 18) course in drawing 13 , of course.
[0050] Moreover, as shown, for example in drawing 15 , you may communalize NFS server 12-i and the external node 19. That is, it constitutes so that file processing according to the request directly received from the external network 3 in NFS server 12-i may be performed to a secondary storage 17. When NFS server 12-i functions as a file server of the storage system 1 mentioned above by this when a certain client 2 has accessed by the redirector 11 course, and NFS server 12-i has been accessed directly, it will function as a usual file server which answers without going via a redirector 11. That is, the both sides of access by the NFS server 12-i course from a client 2 and the direct access which does not go via NFS server 12-i are permitted.
[0051] The direct access from the outside of any case becomes possible, and fusion to other storage architecture [SAN (Storage Area Network) etc.] can be realized. In addition, in drawing 14 and drawing 15 , a sign 20 expresses the network disk adapter which equips the interface of the internal network 14 and a secondary storage 17.
[0052] Moreover, although the shared memory 15 mentioned above is omitted with the composition shown in drawing 13 - drawing 15 , of course, it may be equipped. If it does in this way, also in the composition shown in drawing 13 - drawing 15 , the same backup processing as the above will be attained.
(D) In addition, although the operation gestalt mentioned above, in addition, explained the case where Gigabit Ethernet was applied as Infiniband and an external network 3 as an internal network 14, of course, it is also possible to carry out a system construction using other high-speed networks other than these.
[0053] Moreover, it is not necessary to necessarily offer an above-mentioned name server 13 and an above-mentioned shared memory 15, and even if it omits these either or both sides, the purpose of this invention is attained enough. Furthermore, although NFS is applied to the file server with the operation gestalt mentioned above, this invention is not limited to this but, of course, it is also possible to apply other file systems.
[0054] Moreover, although premised on the capacity (transmission speed) of the internal network 14 being about 4-10Gbps with the operation gestalt mentioned above, this speed can respond, if it changes suitably according to band expansion of the external network 3. And this invention is not limited to the operation gestalt mentioned above, but in the range which does not deviate from the meaning of this invention besides the above, can deform variously and can be carried out.
[0055] (E) Additional remark [additional remark 1] Storage which can memorize file data, Two or more file servers which perform file processing according to the request to this storage, The transfer processing to this file server of the request received from a client through an external network, The file server management node which carries out unitary management of the response processing to this client to this request, The storage system characterized by having offered the internal network which interconnects this storage, this file server, and this file server management node possible [communication], and being constituted.
[0056] [Additional remark 2] Storage system of the additional remark 1 publication characterized by connecting the name server which carries out unitary management of the file data name which this file server treats to this internal network.

[Additional remark 3] Storage system of the additional remark 1 publication characterized by connecting the shared memory with accessible this file server management node and this file server to this internal network.
[0057] [Additional remark 4] Storage system of the additional remark 2 publication characterized by connecting the shared memory with accessible this file server management node, this file server, and this name server to this internal network.
[Additional remark 5] Storage system given in any 1 term of additional remarks 1-4 characterized by having offered the request analysis section in which this file server management node analyzes the content of this request, and the request transfer section which transmits this request to a specific file server according to the analysis result of this request analysis section.
[0058] [Additional remark 6] Storage system of the additional remark 5 publication which offers the transfer history Records Department where this file server management node records the transfer history of the request of the past by this request transfer section, and is characterized by being constituted so that this request transfer section may transmit the request to the file data of the same file data name to the same file server based on this transfer history of this transfer history Records Department.
[0059] [Additional remark 7] Storage system of the additional remark 5 publication which this file server management node offers the load Monitoring Department which supervises the load of this file server, and is characterized by constituting this request transfer section so that this request may be transmitted to the low file server of a load based on the surveillance result in this load Monitoring Department.
[0060] [Additional remark 8] Storage system of the additional remark 5 publication which offers the primary storage to which at least one in this file server can carry out the cache of the file data in this storage, and is characterized by being constituted as a cache server which performs file processing according to this request in this primary storage.
[Additional remark 9] Storage system of the additional remark 8 publication characterized by being constituted so that this request transfer section may transmit the request about file data with the above-mentioned high request frequency to this cache server while this primary storage of this cache server was constituted so that the request frequency within a fixed period might carry out the cache of the file data more than the number of times of predetermined.
[0061] [Additional remark 10] Storage system of the additional remark 9 publication characterized by being constituted so that the destination of this request may be changed into file servers other than this cache server when the request frequency to this file data by which the cache of this request transfer section is carried out to this primary storage of this cache server became below the number of times of predetermined.
[0062] [Additional remark 11] The storage system of the additional remark 5 publication which carries out [having offered the header offset value analysis section which calculates the header offset value as which this request analysis section analyzes this request, and expresses the boundary position of the header unit of the request concerned, and the real file data section, and header offset pricing Kabe who add this header offset value acquired in this header offset value analysis section to this request to which it is transmitted to this file server, and] as the feature.

[0063] [Additional remark 12] Storage system of the additional remark 11 publication characterized by having offered the network driver by which this file server copies this header unit and these data division of this request to the field to which the messages treated in a kernel high order layer, respectively differ based on this header offset value added to this request.
[Additional remark 13] Storage system given in any 1 term of additional remarks 1-12 characterized by having offered the cache section to which this file server management node carries out the cache of the response message to this client about specific file data with high request frequency, and the response section which returns the applicable response message of this cache section to this client as this request is a thing about this specific file data.
[0064] [Additional remark 14] Storage system given in the additional remark 3 or additional remark 4 characterized by having offered the taking over information Records Department which

succeeds information required for this file server to offer at the time of a heterology, and take over processing to other file servers, and records on this shared memory as information.
[Additional remark 15] Storage system of the additional remark 14 publication characterized by preparing the malfunction detection section which detects the heterology of this file server, and the taking over directions section which will give [succeeding processing of this unusual file server based on this taking over information on this shared memory to other file servers other than the file server (henceforth an unusual file server) concerned and] taking over directions if the heterology of this file server is detected in this malfunction detection section.
[0065] [Additional remark 16] Storage system given in any 1 term of additional remarks 1-15 characterized by constituting this storage so that access from an external node may be permitted.
[Additional remark 17] Storage system given in any 1 term of additional remarks 2-15 characterized by constituting this name server so that access from an external node may be permitted.
[0066] [Additional remark 18] Storage system given in any 1 term of additional remarks 1-17 characterized by being constituted so that this file server may perform file processing according to the request received directly from this external network to this storage.
[0067]
[Effect of the Invention] Two or more file servers which perform file processing according to the request to storage according to the storage system of this invention as explained in full detail above, Since the internal network which interconnects the file server management node which carries out unitary management of the processing of each file server, and storage, a file server and a file server management node possible [communication] is offered Since a file server and storage can be extended easily if needed and it moreover is not necessary to maintain each file server separately (maintenance) The performance and capacity scalability which can fully respond by the low cost to band expansion of an external network are securable.
[0068] And if the name server which carries out unitary management of the file data name which each above-mentioned file server treats to the above-mentioned internal network is connected, since it can prevent that file access competition arises between file servers, it contributes to the improvement in reliability of file sharing greatly. Moreover, though an obstacle occurs in some file servers, since processing normal as a storage system is continuable by memorizing the taking over information on the file server which connected the shared memory to the above-mentioned internal network, and was offered on it at this shared memory at the time of obstacle generating at any time, obstacle-proof nature improves sharply.
[0069] Furthermore, if a file server management node may be constituted so that the request to the file data of the same file data name may be transmitted to the same file server based on the transfer history of the past request, and it does in this way, its processing speed will improve sharply. Moreover, if the load of a file server is supervised, you may make it transmit a request to the low file server of a load and it does in this way, since a request can be uniformly transmitted to each file server, what a load concentrates on some file servers and causes an obstacle can be prevented certainly, and reliability improves it sharply.
[0070] Furthermore, about file data with high request frequency, if the cache is carried out to the primary storage of a cache server and it is made to process by the cache server, since the access frequency to storage is sharply reducible, processing speed and processability ability improve further. And if the request frequency to the file data by which the cache is carried out to the primary storage of a cache server in this case becomes below the number of times of predetermined and it will be made to process by file servers other than a cache server Since it is avoided that the low file data of request frequency continues being held forever at a cache server While memory space required for the primary storage of a cache server is reducible, a margin can be given to processing by the cache server and the throughput can be improved.
[0071] Moreover, in a file server management node, the header offset value showing the boundary position of the header unit of a request and the real file data section is calculated, and if the header offset value is added to a request and it is made to transmit to a file server, in the network driver of a file server, the header unit and data division of a request can be copied to

the field to which the messages treated in a kernel high order layer, respectively differ based on the header offset value. Therefore, the zero copy in a kernel can be realized and the processing speed and the throughput of a file server can be improved sharply.
[0072] Furthermore, if the response message which carries out the cache of the response message to the client about specific file data with high request frequency, and carried out the cache to the received request being a thing about the file data in the above-mentioned file server management node is returned to a client, since there will be no need of transmitting a request to a file server, the speed of response to a client will improve sharply, and the processing speed and the throughput as this system will improve by leaps and bounds.
[0073] Moreover, if the above-mentioned storage may be constituted so that access from an external node may be permitted, and it does in this way, fusion to other storage architecture will be attained. If access to the above-mentioned name server [node / external] is permitted here, the file access from an external node will become possible, without needing file access mediation control with the above-mentioned file server and an external node.
[0074] Furthermore, if the above-mentioned file server may be constituted so that file processing according to the request received directly may be performed from the above-mentioned external network to storage, and it does in this way, since the both sides of access via the file server from a client and the direct access which does not go via a file server are permissible, fusion to other storage architecture is attained also in this case.

[Translation done.]

* NOTICES *

1.This document has been translated by computer. So the translation may not reflect the original precisely.
2.**** shows the word which can not be translated.
3.In the drawings, any words are not translated.

DESCRIPTION OF DRAWINGS

[Brief Description of the Drawings]
[Drawing 1] It is the block diagram showing the storage structure of a system (storage architecture) as 1 operation gestalt of this invention.
[Drawing 2] It is the block diagram showing the composition of a redirector shown in drawing 1 .
[Drawing 3] It is a block diagram for explaining the case where the cache of the meta-information is carried out by the redirector shown in drawing 1 .
[Drawing 4] It is a block diagram for explaining the case where a reply message is returned by the redirector shown in drawing 1 .
[Drawing 5] It is the block diagram showing the composition of an NFS server (name server) shown in drawing 1 .
[Drawing 6] It is a block diagram for explaining the case where the taking over information on an NFS server is backed up to the shared memory shown in drawing 1 .
[Drawing 7] It is a block diagram for explaining the case where processing of the NFS server which was backed up by the shared memory shown in drawing 6 and which succeeded and was downed based on information is succeeded.
[Drawing 8] It is a block diagram for explaining the case where the taking over information on a name server is backed up to the shared memory shown in drawing 1 .
[Drawing 9] It is a block diagram for explaining the case where the boundary information on a file access request is searched for in the redirector shown in drawing 1 .
[Drawing 10] It is a block diagram for explaining the case where the zero copy in a kernel is realized based on the boundary information on the file access request shown in drawing 9 in the NFS server shown in drawing 1 .
[Drawing 11] It is a block diagram for explaining the case where the zero copy in a kernel is realized based on the boundary information on the file access request shown in drawing 9 in the NFS server shown in drawing 1 .
[Drawing 12] It is drawing showing the example of a format of the file access request shown in drawing 9 - drawing 11 .
[Drawing 13] It is the block diagram showing the composition in the case of permitting access to the secondary storage from an external node in the storage system shown in drawing 1 .
[Drawing 14] It is the block diagram showing the composition in the case of permitting access to the name server from an external node in the storage system shown in drawing 1 .
[Drawing 15] It is a composition **** block diagram in the case of permitting access via the redirector from an external node, and direct access in the storage system shown in drawing 1 .
[Drawing 16] It is a block diagram for explaining the conventional technique of realizing file sharing between two or more nodes (client) on a network.
[Description of Notations]
1 Storage System
2 Client
3 External Network (Gigabit Ethernet)
11 Redirector (Redirector; File Server Management Node)
11a Gigabit Ethernet card

11b In FINI band card
11c Network processor
11d Memory (primary storage)
11e PCI (Peripheral Component Interconnect) bus
11f Cache memory (cache section)
12-1 - 12-n NFS (Network File System) server (file server)
12' Cache server
12a,13a CPU(Central Processing Unit)
12b, 13b Memory (primary storage)
12c, 13c Interface card (IB-IF)
13 Name Server
14 High-speed (Interior) Network [in FINI Band (Infiniband)] Switch
15 Shared Memory (Shared Memory)
15-1 - 15-m Memory card (Shared Memory Card)
16 IB-FC Card
17 Secondary Storage
18 FC Switch
19 External Node
20 Network Disk Adapter
21 Header Unit
21a Physical-layer header (Phy Header)
21b IP header (Internet Protocol Header)
21c TCP header (Transmission Control Protocol Header)
21d NFS header
22 Real File Data Section
23 Header Offset Value (Boundary Information)
111 Request Analysis Section
111a Header offset value analysis section
111b Header offset pricing Kabe
112 Request Transfer Section
113 Transfer History Records Department
114 Load Monitoring Department
115 NFS Server Load Surveillance Demon (Daemon)
116 Response Section
121,131 Taking over information Records Department
122 NIC (Network Interface Card) Driver (Network Driver)
123,124 Buffer (mbuf)
125 File System Section
126 File System Buffer
132 NFS Server Surveillance Demon
133 Name Server Surveillance Demon
134 Malfunction Detection Section
135 Taking over Directions Section

[Translation done.]

(19)日本国特許庁（ＪＰ）　(12) **公開特許公報（Ａ）**　(11)特許出願公開番号
特開2002－163140
（P2002－163140A）
(43)公開日　平成14年６月７日(2002.6.7)

(51)Int.Cl.'	識別記号	ＦＩ		テーマコード'(参考)
Ｇ０６Ｆ　12/00	５４５	Ｇ０６Ｆ　12/00	５４５Ｂ	５Ｂ０１４
13/10	３４０	13/10	３４０Ａ	５Ｂ０８２

審査請求　未請求　請求項の数５　ＯＬ　（全 16 頁）

(21)出願番号　特願2000－359810(P2000－359810)

(22)出願日　平成12年11月27日(2000.11.27)

(71)出願人　000005223
富士通株式会社
神奈川県川崎市中原区上小田中４丁目１番１号
(72)発明者　大江　和一
神奈川県川崎市中原区上小田中４丁目１番１号　富士通株式会社内
(72)発明者　西川　克彦
神奈川県川崎市中原区上小田中４丁目１番１号　富士通株式会社内
(74)代理人　100092978
弁理士　真田　有

Ｆターム(参考)　5B014 EB04 FA05
5B082 AA01 FA16 HA01 HA05 HA08

(54)【発明の名称】　ストレージシステム

(57)【要約】
【課題】　ネットワークの帯域拡大に対して低コストで十分に対応できるスケーラビリティをもったストレージシステムを提供することを目的とする。
【解決手段】　ファイルデータを記憶しうる記憶装置１７と、ファイルデータに関するリクエストに応じたファイル処理を記憶装置１７に対して行なう複数のファイルサーバ１２－１～１２－ｎと、外部ネットワーク３を介してクライアント２から受信されるファイルリクエストのファイルサーバ１２－ｉ（ｉ＝１～ｎ）への転送処理と、そのファイルリクエストに対するクライアント２への応答処理とを管理するファイルサーバ管理ノード１１と、記憶装置１７，ファイルサーバ１２－ｉ及びファイルサーバ管理ノード１１を通信可能に相互接続する内部ネットワーク１４とをそなえるように構成する。

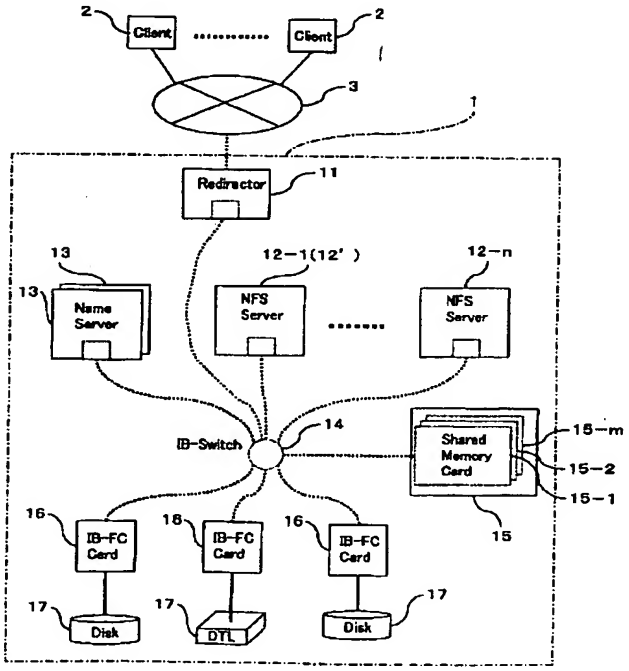

【特許請求の範囲】
【請求項１】　ファイルデータを記憶しうる記憶装置と、
該ファイルデータに関するリクエストに応じたファイル処理を該記憶装置に対して行なう複数のファイルサーバと、
外部ネットワークを介してクライアントから受信されるリクエストの該ファイルサーバへの転送処理と、該リクエストに対する該クライアントへの応答処理とを一元管理するファイルサーバ管理ノードと、
該記憶装置，該ファイルサーバ及び該ファイルサーバ管理ノードを通信可能に相互接続する内部ネットワークとをそなえて構成されたことを特徴とする、ストレージシステム。
【請求項２】　該内部ネットワークに、該ファイルサーバが扱うファイルデータ名を一元管理するネームサーバが接続されていることを特徴とする、請求項１記載のストレージシステム。
【請求項３】　該内部ネットワークに、該ファイルサーバ管理ノード及び該ファイルサーバがアクセス可能な共有メモリが接続されていることを特徴とする、請求項１記載のストレージシステム。
【請求項４】　該内部ネットワークに、該ファイルサーバ管理ノード，該ファイルサーバ及び該ネームサーバがアクセス可能な共有メモリが接続されていることを特徴とする、請求項２記載のストレージシステム。
【請求項５】　該ファイルサーバ管理ノードが、
該リクエストの内容を解析するリクエスト解析部と、
該リクエスト解析部の解析結果に応じて該リクエストを特定のファイルサーバに転送するリクエスト転送部とをそなえていることを特徴とする、請求項１～４のいずれか１項に記載のストレージシステム。
【発明の詳細な説明】
【０００１】
【発明の属する技術分野】本発明は、ストレージシステムに関し、所望のネットワークに接続されることで複数のクライアントでファイルデータの共有を可能にするストレージシステムに関する。
【０００２】
【従来の技術】ネットワーク上での複数ノード（クライアント）間のファイルデータの共有（以下、単に、「ファイル共有」という）を実現する従来の手法としては、例えば図１６に模式的に示すように、ネットワークファイルシステム（ＮＦＳ：Network File System）を利用してＬＡＮ（Local Area Network）などの所望のネットワーク１００上にファイルサーバ２００を構築し、このファイルサーバ２００にＳＣＳＩ（Small Computer System Interface；一般に「スカジー」と呼ばれる）などのインタフェース３００を介して二次記憶装置４００を接続して、この二次記憶装置４００において複数クライアント５００間のファイル共有を実現する方法が良く知られている。
【０００３】しかしながら、この方法では、次のような課題がある。
①ファイルサーバを構築・維持（保守）するのに専門的なスキルが必要である。
②ファイルサーバの拡張（容量，アクセス性能）が容易でない。拡張できてもファイルサーバが複数に分かれたりしてしまうなどで維持コストが増大してしまう。
【０００４】③故障時にそなえたシステム構築・維持（保守）に専門的なスキルが必要であり、また、そのための費用もかかる。
これらの課題を解決する方法として、近年、ＮＡＳ（Network Attached Storage）が提案されている。このＮＡＳは、上記のファイルサーバ２００及び二次記憶装置４００から成る部分（図１６中の破線枠参照）が予め１つのストレージシステムとして構築されたものに相当し、ネットワーク１００に接続して簡単な設定を行なうだけで、ファイル共有が実現できるシステムで、システムの構築・維持（保守）に専門的なスキルは必要ない。
【０００５】
【発明が解決しようとする課題】しかしながら、このようなＮＡＳにおいても、現在急速に進んでいるＬＡＮの帯域拡大（現状で１Ｇｂｐｓ，数年後には１０Ｇｂｐｓ程度）に低コストで十分に対応できるスケーラビリティが得られていないという課題は残っている。即ち、接続先のネットワークの帯域拡大に対応しようとすると、ＮＡＳにおいても、単純に、内部のファイルサーバ及び二次記憶装置を増設することになり、この結果、ファイルサーバが複数に分かれてしまい、それぞれが管理する二次記憶装置も分割されてしまうことになる。
【０００６】つまり、上記のファイルサーバ２００及び二次記憶装置４００を並列（独立）して設けることになる。このため、結局、ファイルサーバの維持（保守）を個々に行なう必要があり、維持コストが増大してしまう。本発明は、このような課題に鑑み創案されたもので、ネットワークの帯域拡大に対して低コストで十分に対応できるスケーラビリティをもったストレージシステムを提供することを目的とする。
【０００７】
【課題を解決するための手段】上記の目的を達成するために、本発明のストレージシステム（請求項１）は、ファイルデータを記憶しうる記憶装置と、この記憶装置に対しリクエストに応じたファイル処理を行なう複数のファイルサーバと、外部ネットワークを介してクライアントから受信されるリクエストの上記ファイルサーバへの転送処理と、そのリクエストに対するクライアントへの応答処理とを一元管理するファイルサーバ管理ノードと、上記の記憶装置，ファイルサーバ及びファイルサーバ管理ノードを通信可能に相互接続する内部ネットワー

クとをそなえて構成されたことを特徴としている。

【０００８】ここで、上記の内部ネットワークには、上記のファイルサーバが扱うファイルデータ名を一元管理するネームサーバが接続されていてもよいし（請求項２）、上記のファイルサーバ管理ノード及びファイルサーバがアクセス可能な共有メモリが接続されていてもよい（請求項３）。なお、上記のネームサーバが存在する場合は、上記のファイルサーバ管理ノード及びファイルサーバに加えて、このネームサーバも上記の共有メモリにアクセスが可能である（請求項４）。

【０００９】また、上記のファイルサーバ管理ノードは、例えば、上記のリクエストの内容を解析するリクエスト解析部と、このリクエスト解析部の解析結果に応じて該リクエストを特定のファイルサーバに転送するリクエスト転送部とをそなえて構成されるのが好ましい（請求項５）。

【００１０】

【発明の実施の形態】以下、図面を参照して本発明の実施の形態を説明する。

（Ａ）一実施形態の説明

図１は本発明の一実施形態としてのストレージシステムの構成（ストレージアーキテクチャ）を示すブロック図で、この図１に示すストレージシステム１（以下、単に「システム１」ともいう）は、外部ネットワーク（例えば、ギガビットイーサネット（登録商標））３に接続された複数のクライアント２間でファイル共有を実現するためのものであって、リダイレクタ（Redirector）１１，複数のＮＦＳサーバ（ファイルサーバ）１２－１～１２－ｎ，ネームサーバ１３，共有メモリ（Shared Memory）１５，ＩＢ－ＦＣカード１６，二次記憶装置１７〔ディスク装置やテープ装置（ＤＴＬ）など〕をそなえており、これらの各コンポーネント１１，１２－ｉ，１３，１５，１６，１７が例えば４～１０Ｇｂｐｓ（ギガビット／秒）程度の高速（内部）ネットワーク〔インフィニバンド（Infiniband）〕スイッチ）１４を介して相互に接続された構成になっている。

【００１１】このようにシステム内部の各コンポーネント（リダイレクタ１１，ＮＦＳサーバ１２－ｉ，ネームサーバ１３，二次記憶装置１７など）を内部ネットワーク１４で接続する形態（クラスタリング）をとることで、必要に応じてＮＦＳサーバ１２－ｉや二次記憶装置１７を内部ネットワーク１４に接続すれば簡単に増設することができ、外部ネットワーク３の通信速度などに応じた拡張性（容量，アクセス性能など）が大幅に向上する。

【００１２】ここで、上記のリダイレクタ（ファイルサーバ管理ノード）１１は、外部ネットワーク３を介して任意のクライアント２から受信される各種リクエストメッセージ（以下、単に「リクエスト」という）のＮＦＳサーバ１２－ｉ（ｉ＝１～ｎ）への転送処理と、そのリクエストに対するリクエスト元のクライアント２への応答処理とを一元（集中）管理するためのものである。つまり、本リダイレクタ１１の存在により、上述のごとくＮＦＳサーバ１２－ｉや二次記憶装置１７を増設したとしても、従来のようにそれらを個々に保守する必要は無いのである。

【００１３】なお、上記の「リクエスト」は、二次記憶装置１７に記憶されたファイルデータ（以下、単に「ファイル」ともいう）に関する要求を意味し、例えば、ファイルデータの実体に対するファイル操作（書き込み／更新／読み出しなど）要求（ファイルアクセスリクエスト）や、それ以外のファイル名参照などのメタ情報アクセスなどがある。また、各クライアント２からは、基本的に、このリダイレクタ１１に付与されたＩＰ（Internet Protocol）アドレスのみが参照できる。つまり、各クライアント２からは、本システム１が１つのファイルサーバとして見えるようになっている。

【００１４】そして、上述したような機能を実現すべく、本リダイレクタ１１には、例えば図２に示すように、外部ネットワーク３用のインタフェースを装備するギガビットイーサネットカード１１ａ、システム内部（内部ネットワーク）用のインタフェースを装備するインフィニバンドカード１１ｂ、これらの各カード１１ａ，１１ｂをはじめとして自身（リダイレクタ１１）の動作を集中制御するためのネットワークプロセッサ１１ｃ、このネットワークプロセッサ１１ｃが動作する上で必要なソフトウェア（プログラム）や各種データを記憶するためのメモリ（主記憶部）１１ｄなどが実装される。

【００１５】なお、ネットワークプロセッサ１１ｃは、これらのコンポーネント１１ａ～１１ｄとＰＣＩ（Peripheral Component Interconnect）バス１１ｅを介して相互通信可能に接続されている。ここで、上記のネットワークプロセッサ１１ｃは、内部ネットワーク１４と外部ネットワーク３との間で送受されるリクエストやそのリクエストに対するリプライ（応答）メッセージなどの送受（プロトコル変換なども含む）や、クライアント２から受信されるリクエスト（プロトコル）の解析，その解析結果に基づいたアクセスファイル名の決定，受信リクエストの転送先ＮＦＳサーバ１２－ｉの決定などを行なうことができるもので、本実施形態では、次のような制御も可能になっている。

【００１６】即ち、クライアント２からのリクエストを解析し、各ファイルサーバ１２－ｉに均一に（例えば、負荷の軽いＮＦＳサーバ１２－ｉに）リクエストが転送されるように制御したり、同一ファイルについてのリクエストは同じＮＦＳサーバ１２－ｉに割り当てて、ＮＦＳサーバ１２－ｉ間でファイルアクセス競合が起きないように制御したりすることができるようになっている。

【００１７】このため、本ネットワークプロセッサ１１

ｃには、その要部の機能に着目すると、次のような機能部が実装されている。

（１）クライアント２からのリクエストの内容を解析するリクエスト解析部１１１としての機能

（２）このリクエスト解析部１１１の解析結果に応じて受信リクエストを特定のＮＦＳサーバ１２－ｉに転送するリクエスト転送部１１２としての機能

（３）リクエスト転送部１１２による過去のリクエストの転送履歴を（例えば、メモリ１１ｄに）記録する転送履歴記録部１１３としての機能

（４）ＮＦＳサーバ負荷監視デーモン（daemon）１１５をバックグラウンドで実行することにより、各ＮＦＳサーバ１２－ｉの負荷状態を定期的に監視する負荷監視部１１４としての機能

これにより、上記のリクエスト転送部１１２は、上記の転送履歴記録部１１３による転送履歴に基づいて同一ファイル名のファイルに対するリクエストを同一ＮＦＳサーバ１２－ｉに転送したり、ＮＦＳサーバ負荷監視デーモン１１５（負荷監視部１１４）による負荷監視結果に基づいて負荷の低いＮＦＳ１２－ｉに受信リクエストを転送したりすることが可能になる。

【００１８】従って、処理速度が大幅に向上するとともに、各ＮＦＳサーバ１２－ｉに均一にリクエストを転送できるので、一部のＮＦＳサーバ１２－ｉに負荷が集中して障害を引き起こしてしまうようなことを確実に防止することができ、信頼性が大幅に向上する。なお、本ネットワークプロセッサ１１ｃは、例えば、メタ情報アクセスに対するリプライメッセージを内部のキャッシュメモリ１１ｆ（メモリ１１ｄでもよい）にキャッシュしておき（図３参照）、クライアント２からメタ情報アクセスについてのリクエストを受けると、まず、キャッシュメモリ１１ｆ（あるいは、メモリ１１ｄ）をチェックして、ヒットすればリプライメッセージを作成してそのまま（ＮＦＳサーバ１２－ｉやネームサーバ１３に転送することなく）クライアント２側に返す（図４参照）ようにすることもできる。

【００１９】この仕組みは、メタ情報のみならずファイルデータについても適用できる。ただし、この場合、全てのファイルデータをキャッシュするようにすると必要なメモリ容量が増大するので、ネットワークプロセッサ１１ｃでアクセス頻度の高いファイルデータを選び出し、そのファイルデータのみをキャッシュメモリ１１ｆ（あるいは、メモリ１１ｄ）にキャッシュするようにした方が良い。

【００２０】つまり、上記のキャッシュメモリ１１ｆ（あるいは、メモリ１１ｄ）は、リクエスト頻度の高い特定のファイルデータについてのクライアント２へのリプライメッセージをキャッシュしておくキャッシュ部としての機能も果たし、この場合のネットワークプロセッサ１１ｃは、新たなリクエストが同じファイルについてのものであると、キャッシュメモリ１１ｆ（あるいは、メモリ１１ｄ）にキャッシュしておいたリプライメッセージをクライアント２へ返す応答部１１６（図２参照）としての機能も有していることになる。

【００２１】このようにして、アクセス頻度の高い情報（メタ情報，ファイルデータ）に関しては、リダイレクタ１１側でキャッシュして、ＮＦＳサーバ１２－ｉにリクエストを転送することなくリダイレクタ１１で応答を返してしまえば、アクセス頻度が高い情報に対するクライアント２への応答速度が大幅に向上し、本システム１としての処理速度及び処理能力が飛躍的に向上することになる。

【００２２】次に、上記のＮＦＳサーバ１２－ｉは、それぞれ、リダイレクタ１１から転送されてきたリクエストに応じたファイル処理（書き込み／更新／読み出しなど）を、内部ネットワーク（内部ネットワークスイッチ）１４経由で二次記憶装置１７にアクセスして実施したり、そのファイル処理結果をリクエスト元のクライアント２への応答として送付するためのリプライメッセージを生成してリダイレクタ１１に送信したりすることができるものである。

【００２３】なお、ＮＦＳサーバ１２－ｉは、いずれも、ハードウェア的には、例えば図５に示すように、ＣＰＵ（Central Processing Unit）１２ａ，メモリ（主記憶部）１２ｂ及び内部ネットワーク１４とのインタフェース（プロトコル変換など）を装備するインタフェースカード（ＩＢ－ＩＦ）１２ｃをそなえて構成され、メモリ１２ｂに記憶されたＮＦＳサーバソフトウェア（プログラム）をＣＰＵ１２ａが読み取って動作することにより、上述したＮＦＳサーバ１２－ｉとしての機能が実現されるようになっている。

【００２４】さて、ここで、これらのＮＦＳサーバ１２－ｉが、それぞれ独自にファイル名を管理すると、同じファイルデータ実体であるにも関わらず異なるＮＦＳサーバ１２－ｉで管理ファイル名が異なったり、逆に、異なるファイルデータ実体であるにも関わらず異なるＮＦＳサーバ１２－ｉで同じ管理ファイル名になったりといった不都合が生じ、ＮＦＳサーバ１２－ｉ間でファイルアクセス競合が生じる可能性がある。

【００２５】このような不都合を解決するのが上記のネームサーバ１３である。つまり、このネームサーバ１３において、ＮＦＳサーバ１２－ｉからのメタ情報アクセスを一元管理することで、全てのＮＦＳサーバ１２－ｉにおける管理ファイル名空間を１つにして、ＮＦＳサーバ１２－ｉ間でのファイルアクセス競合を回避するのである。従って、このネームサーバ１３をそなえることにより、本システム１によるファイル共有の信頼性が大幅に向上することとなる。

【００２６】なお、図１中に示すように、本ネームサーバ１３には、故障などの異常発生（ダウン）にそなえて

現用と予備用とが存在する。また、これらのネームサーバ１３についても、ハードウェア的には、ＮＦＳサーバ１２－ｉと同様の構成（図５参照）、即ち、ＣＰＵ１３ａ，メモリ（主記憶部）１３ｂ及び内部ネットワーク１４とのインタフェースを装備するインタフェースカード１３ｃが実装されており、この場合も、メモリ１３ｂに記憶されたネームサーバソフトウェア（プログラム）をＣＰＵ１３ａが読み取って動作することにより、上述したネームサーバ１３としての機能が実現されるようになっている。

【００２７】次に、上記の共有メモリ１５は、上記のリダイレクタ１１，ＮＦＳサーバ１２－ｉ及びネームサーバ１３がそれぞれ内部ネットワーク１４を介してアクセス可能なメモリで、例えば、或るＮＦＳサーバ１２－ｉあるいは現用のネームサーバ１３がダウンした場合（障害発生時）に、そのＮＦＳサーバ１２－ｉあるいは現用のネームサーバ１３の処理を他のＮＦＳサーバ１２－ｋ（ｋ＝１～ｎでｋ≠ｉ）あるいは予備用のネームサーバ１３に引継ぐための情報（以下、引継ぎ情報）などがサーバ１２－ｉ，１３別にメモリカード（Shared Memory Card）１５－１～１５－ｍ（ｍは自然数）に保持（バックアップ）されるようになっている（図６及び図８参照）。

【００２８】つまり、上記の各ＮＦＳサーバ１２－ｉ（ＣＰＵ１２ａ）もしくはネームサーバ１３（ＣＰＵ１３ａ）は、異常発生時にそなえて他のＮＦＳサーバ１２－ｉもしくは予備用のネームサーバ１３に処理を引継ぐのに必要な情報を引継ぎ情報として共有メモリ１５に記録する引継ぎ情報記録部１２１（１３１）（図５参照）としての機能を有していることになる。

【００２９】なお、ＮＦＳサーバ１２－ｉのダウンは、例えば図６に模式的に示すように、現用のネームサーバ１３（ＣＰＵ１３ａ）がＮＦＳサーバ監視デーモン１３２をバックグラウンドで実行することで監視し、現用のネームサーバ１３のダウンは、例えば図８に模式的に示すように、予備用のネームサーバ１３（ＣＰＵ１３ａ）がネームサーバ監視デーモン１３３をバックグラウンドで実行することで監視する。

【００３０】そして、図７に模式的に示すように、ＮＦＳサーバ１２－ｉのダウンが検出された場合（ステップＳ１）は、現用のネームサーバ１３（ＣＰＵ１３ａ）が、ダウンしたＮＦＳサーバ１２－ｉ以外のＮＦＳサーバ１２－ｋ（例えば、負荷の軽いＮＦＳサーバ１２－ｋ）に対して、ダウンしたＮＦＳサーバ１２－ｉの処理を引継ぐよう指示するとともに、リダイレクタ１１に対してＮＦＳサーバ１２－ｉのダウンを通知する（ステップＳ２）。

【００３１】これにより、引継ぎ指示を受けたＮＦＳサーバ１２－ｋ（ＣＰＵ１２ａ）は、共有メモリ１５に内部ネットワーク１４を介してアクセスして、そこにバックアップされている引継ぎ情報を読み出してダウンしたＮＦＳサーバ１２－ｉの処理を引継ぐ（ステップＳ３）。一方、このとき、リダイレクタ１１（ネットワークプロセッサ１１ｃ）は、ネームサーバ１３から上記の通知を受けることにより、ダウンしたＮＦＳサーバ１２－ｉにはリクエスト転送部１１２によるリクエストの転送を行なわないようにする。

【００３２】つまり、この場合のネームサーバ１３（ＣＰＵ１３ａ）は、ＮＦＳサーバ１２－ｉの異常発生を検出する異常検出部１３４（図６参照）と、この異常検出部１３４でＮＦＳサーバ１２－ｉの異常発生が検出されると、そのＮＦＳサーバ１２－ｉ以外の他のＮＦＳサーバ１２－ｋに対して異常発生したＮＦＳサーバ１２－ｉの処理を共有メモリ１５の引継ぎ情報に基づいて引継ぐよう引継ぎ指示を与える引継ぎ指示部１３５（図６参照）としての機能を有していることになる。

【００３３】このように、本実施形態では、たとえ、ＮＦＳサーバ１２－ｉやネームサーバ１３がダウンしたとしても、他のＮＦＳサーバ１２－ｋや予備用のネームサーバ１３が処理を引継ぐことができるので、ストレージシステム１としては正常なファイル処理を継続することができ、耐障害性が大幅に向上する。なお、本例は、ＮＦＳサーバ１２－ｉやネームサーバ１３の冗長化についての説明であるが、勿論、リダイレクタ１１を同様にして冗長化することも可能である。また、現用のネームサーバ１３ダウン時の引継ぎについては、場合によってはＮＦＳサーバ１２－ｉのいずれかに引継ぐようにしてもよい。

【００３４】次に、上述したリダイレクタ１１からＮＦＳサーバ１２－ｉへのリクエスト転送時のリダイレクタ１１及びＮＦＳサーバ１２－ｉでの具体的な処理について説明する。リダイレクタ１１は、例えば、クライアント２から或るファイルデータを書き込むためのファイルアクセスリクエストを受信すると、そのファイルアクセスリクエストをリクエスト解析部１１１にて解析する。

【００３５】なお、上記の「ファイルアクセスリクエスト」は、例えば図１２に示すように、物理レイヤヘッダ（Phy Header）２１ａやＩＰヘッダ（Internet Protocol Header）２１ｂ，ＴＣＰヘッダ（Transmission Control Protocol Header）２１ｃ，ＮＦＳヘッダ２１ｄなどから成るヘッダ部２１と、実際に二次記憶装置１７に書き込むべきファイルデータの実体（実ファイルデータ）が格納された実ファイルデータ部２２とを有して成る。

【００３６】そして、リクエスト解析部１１１は、図９に模式的に示すように、上記のファイルアクセスリクエスト中の実ファイルデータが始まる位置、即ち、ヘッダ部２１と実ファイルデータ部２２との境界をヘッダオフセット値〔境界情報；例えば先頭からのビット数（“ａ”）など〕２３として求める。求められた境界情報２３は、リクエスト転送部１１２に通知され、リクエ

スト転送部１１２は、上記ファイルアクセスリクエストに通知された境界情報２３を添付（付加）して転送先のＮＦＳサーバ１２－ｉに送付する。

【００３７】つまり、上記のリクエスト解析部１１１は、図２中に示すように、受信したファイルアクセスリクエストを解析してそのファイルアクセスリクエストのヘッダ部２１と実ファイルデータ部２２との境界位置を表わすヘッダオフセット値２３を求めるヘッダオフセット値解析部１１１ａとしての機能と、このヘッダオフセット値解析部１１１ａで得られたヘッダオフセット値２３をＮＦＳサーバ１２－ｉへ転送されるファイルアクセスリクエストに付加するヘッダオフセット値付加部１１１ｂとしての機能とを有していることになる。

【００３８】その後、ＮＦＳサーバ１２－ｉ側では、上述のごとくリダイレクタ１１側で付加されたヘッダオフセット値２３に基づいて、ＮＩＣ（Network Interface Card）ドライバ（ネットワークドライバ）１２２が、実ファイルデータ部２２とそれ以外の領域（ヘッダ部２１）の先頭アドレスをそれぞれ上位層（ＮＦＳ処理層）のカーネル内（カーネル上位層）で扱われるメッセージのページ境界〔ページ境界（別領域）；バッファ（mbuf）１２３，１２４〕に割り当てることができる（図１０参照）。

【００３９】このようにすると、例えば図１１に模式的に示すように、ファイルアクセスリクエストがカーネル上位層のファイルシステム部１２５に到達したときに、実ファイルデータ部２２の先頭アドレス（ポインタ）をファイルシステムバッファ１２６へのポインタに付け替えるだけで、データのコピーを発生させずに（マップ切り替え）、ファイルシステムバッファ１２６にデータを移すことが可能になる（カーネル内ゼロコピーが実現される）。従って、ＤＭＡ（Direct Memory Access）も高速に実行でき、ＮＦＳサーバ１２－ｉの処理速度及び処理能力を大幅に向上することができる。

【００４０】なお、ヘッダ部２１と実ファイルデータ部２２との境界は、ＮＩＣドライバ１２２側で求めるようにすることも考えられるが、この場合、ＮＩＣドライバ１２２の処理（ヘッダ解析）量が増大する（通常、ＮＩＣドライバ１２２は物理レイヤヘッダ２１ａの解析のみを行なう）ため、上記のように元々ヘッダ部２１の解析機能（リクエスト解析部１１１）を有するリダイレクタ１１側で境界を求めるようにした方が、ＮＩＣドライバ層での処理量を増やさずに（処理能力低下を招かずに）上位層（ＮＦＳ処理層）でのカーネルゼロコピーを実現できる。

【００４１】以上のように、本実施形態のストレージシステム１によれば、システム１内部に、リダイレクタ１１，複数のＮＦＳサーバ１２－ｉ，ネームサーバ１３，共有メモリ１５，二次記憶装置１７を設け、これらを高速な内部ネットワーク１４で接続する構成にしたことにより、必要に応じてＮＦＳサーバ１２－ｉや二次記憶装置１７を簡単に増設することができ、しかも、ＮＦＳサーバ１２－ｉの維持（保守）を個々に行なう必要もないので、外部ネットワーク３の帯域拡大に対して低コストで十分に対応できる（例えば、１０ＧｂｐｓＬＡＮまで対応可能な）性能・容量スケーラビリティを確保することができる。

【００４２】特に、上述した実施形態では、リダイレクタ１１が、各ＮＦＳサーバ１２－ｉの負荷に応じて各ＮＦＳサーバ１２－ｉに均一に処理が割り当てられるように制御したり、同じファイルについてのリクエストに対する処理は同じＮＦＳ１２－ｉに割り当てたり、アクセス頻度の高いファイルについてのリクエストに対してはＮＦＳサーバ１２－ｉ側ではなくリダイレクタ１１側でキャッシュしておいたリプライメッセージにより応答したりするので、その処理速度及び性能が飛躍的に向上しており、１０ＧｂｐｓＬＡＮまで確実に対応可能な性能・容量スケーラビリティが実現されている。

【００４３】（Ｂ）第１変形例の説明

上述したシステム１内には、メモリ１２ｂの容量が他のＮＦＳサーバ１２－ｉよりも大きいＮＦＳサーバ１２－ｉをキャッシュサーバ１２′（図１参照）として配置して、このキャッシュサーバ１２′でのファイルアクセスは基本的にメモリ１２ｂに対する読み書きのみでクライアント２側に応答を返すようにしてもよい。

【００４４】そして、一定期間内のリクエスト頻度が所定回数（閾値）以上であるアクセス頻度の高いファイルについてはキャッシュサーバ１２′のメモリ１２ｂにキャッシュしておき、キャッシュサーバ１２′が応答するようにする。具体的には、まず、リダイレクタ１１側で各ファイルのアクセス頻度を監視しておき、アクセス頻度が或る閾値よりも高いファイルへのアクセスに関しては、キャッシュサーバ１２－ｉで処理を行なうように、リダイレクタ１２－ｉからネームサーバ１３，ＮＦＳサーバ１２－ｉ，キャッシュサーバ１２′に指示を与える。

【００４５】つまり、このとき、リダイレクタ１１（リクエスト転送部１１２）は、アクセス頻度の高いファイルについてのリクエストをキャッシュサーバ１２′に転送することになる。これにより、アクセス頻度の高いファイルに対するアクセスは、二次記憶装置１７にアクセスすることなくキャッシュサーバ１２′内で処理されるので、ストレージシステム１としての処理速度及び処理能力の大幅な向上に大きく寄与する。

【００４６】一方、上記のアクセス頻度の高いファイルに対するアクセス頻度が落ちてくると（キャッシュサーバ１２′のメモリ１２ｂにキャッシュされているファイルに対するアクセス頻度が所定回数以下になると）、リダイレクタ１１が適当な（例えば、負荷の軽い）ＮＦＳサーバ１２－ｉを割り当てて処理を移行するようにネー

ムサーバ１３，ＮＦＳサーバ１２－ｉ，キャッシュサーバ１２′に指示する。

【００４７】つまり、この場合、リダイレクタ１１（リクエスト転送部１１２）は、リクエストの転送先をキャッシュサーバ１２′以外のＮＦＳサーバ１２－ｉに変更するのである。これにより、アクセス頻度が落ちてきたファイルがいつまでもキャッシュサーバ１２′にキャッシュされ続けることが回避され、その結果、キャッシュサーバ１２′に必要なメモリ容量を削減することができるとともに、キャッシュサーバ１２′での処理に余裕をもたせてその処理能力を向上することができる。

【００４８】（Ｃ）第２変形例の説明

なお、例えば図１３に示すように、上記の二次記憶装置１７をＦＣスイッチ１８経由でネームサーバ１３及びＮＦＳサーバ１２－ｉと接続（二次記憶ネットワークを構築）し、ＦＣスイッチ１８と外部ノード１９とを接続することにより、二次記憶装置１７に外部ノード１９からもアクセスできるようにすることも可能である。ただし、この場合、外部ノード１９で動作させるファイルシステムは、ストレージシステム１内のファイルシステムと同じもの（上述した例では、ＮＦＳ；図１３中の網かけ部がこれを意味する）である必要がある。

【００４９】このようにすることで、システム１内部のＮＦＳサーバ１２－ｉとのアクセス競合を避けるために外部ノード１９からのアクセスについては何らかの調停制御が必要になるが、外部ノード１９から本ストレージシステム１内のファイルへのアクセスが可能になる。ただし、例えば図１４に示すように、外部ノード１９からネームサーバ１３へのアクセスを許容するようにすれば、外部ノード１９からのアクセスについてもシステム１内の管理ファイル名に従うことになるので、上記の調停制御を必要とせずに外部ノード１９からのファイルアクセスが行なえるようになる。なお、この図１４では、内部ネットワーク１４経由でのネームサーバ１３へのアクセスを許容する場合であるが、勿論、図１３において二次記憶ネットワーク（ＦＣスイッチ１８）経由でのアクセスを許容するようにしてもよい。

【００５０】また、例えば図１５に示すように、ＮＦＳサーバ１２－ｉと外部ノード１９とを共通化してしまってもよい。つまり、ＮＦＳサーバ１２－ｉを、外部ネットワーク３から直接受信されるリクエストに応じたファイル処理を二次記憶装置１７に対して行なうように構成するのである。これにより、或るクライアント２がリダイレクタ１１経由でアクセスしてきた場合は、ＮＦＳサーバ１２－ｉは上述したストレージシステム１のファイルサーバとして機能し、直接、ＮＦＳサーバ１２－ｉにアクセスしてきた場合は、リダイレクタ１１を経由せずに応答する通常のファイルサーバとして機能することになる。つまり、クライアント２からのＮＦＳサーバ１２－ｉ経由でのアクセスとＮＦＳサーバ１２－ｉを経由しない直接アクセスとの双方を許容するのである。

【００５１】いずれの場合も、外部からの直接アクセスが可能となり、他のストレージアーキテクチャ〔例えば、ＳＡＮ（Storage Area Network）など〕との融合を実現することができる。なお、図１４及び図１５において、符号２０は内部ネットワーク１４と二次記憶装置１７とのインタフェースを装備するネットワークディスクアダプタを表す。

【００５２】また、図１３～図１５に示す構成では、前述した共有メモリ１５が省略されているが、勿論、装備されていてもよい。このようにすれば、図１３～図１５に示す構成においても、前記と同様のバックアップ処理が可能になる。

（Ｄ）その他

なお、上述した実施形態では、内部ネットワーク１４としてInfiniband，外部ネットワーク３としてギガビットイーサネットを適用した場合について説明したが、勿論、これら以外の他の高速ネットワークを用いてシステム構築することも可能である。

【００５３】また、上記のネームサーバ１３や共有メモリ１５は必ずしもそなえる必要はなく、これらのいずれか、あるいは、双方を省略しても本発明の目的は十分達成される。さらに、上述した実施形態では、ファイルサーバにＮＦＳを適用しているが、本発明はこれに限定されず、勿論、他のファイルシステムを適用することも可能である。

【００５４】また、上述した実施形態では、内部ネットワーク１４の容量（通信速度）が４～１０Ｇｂｐｓ程度であることを前提としたが、この速度は外部ネットワーク３の帯域拡大に応じて適宜変更すれば対応できる。そして、本発明は、上述した実施形態に限定されず、上記以外にも本発明の趣旨を逸脱しない範囲で種々変形して実施することができる。

【００５５】（Ｅ）付記

〔付記１〕　ファイルデータを記憶しうる記憶装置と、リクエストに応じたファイル処理を該記憶装置に対して行なう複数のファイルサーバと、外部ネットワークを介してクライアントから受信されるリクエストの該ファイルサーバへの転送処理と、該リクエストに対する該クライアントへの応答処理とを一元管理するファイルサーバ管理ノードと、該記憶装置，該ファイルサーバ及び該ファイルサーバ管理ノードを通信可能に相互接続する内部ネットワークとをそなえて構成されたことを特徴とする、ストレージシステム。

【００５６】〔付記２〕　該内部ネットワークに、該ファイルサーバが扱うファイルデータ名を一元管理するネームサーバが接続されていることを特徴とする、付記１記載のストレージシステム。

〔付記３〕　該内部ネットワークに、該ファイルサーバ管理ノード及び該ファイルサーバがアクセス可能な共有

メモリが接続されていることを特徴とする、付記１記載のストレージシステム。

【００５７】〔付記４〕　該内部ネットワークに、該ファイルサーバ管理ノード，該ファイルサーバ及び該ネームサーバがアクセス可能な共有メモリが接続されていることを特徴とする、付記２記載のストレージシステム。

〔付記５〕　該ファイルサーバ管理ノードが、該リクエストの内容を解析するリクエスト解析部と、該リクエスト解析部の解析結果に応じて該リクエストを特定のファイルサーバに転送するリクエスト転送部とをそなえていることを特徴とする、付記１～４のいずれか１項に記載のストレージシステム。

【００５８】〔付記６〕　該ファイルサーバ管理ノードが、該リクエスト転送部による過去のリクエストの転送履歴を記録する転送履歴記録部をそなえ、該リクエスト転送部が、該転送履歴記録部の該転送履歴に基づいて同一ファイルデータ名のファイルデータに対するリクエストを同一ファイルサーバに転送するように構成されたことを特徴とする、付記５記載のストレージシステム。

【００５９】〔付記７〕　該ファイルサーバ管理ノードが、該ファイルサーバの負荷を監視する負荷監視部をそなえ、該リクエスト転送部が、該負荷監視部での監視結果に基づいて負荷の低いファイルサーバに該リクエストを転送するように構成されたことを特徴とする、付記５記載のストレージシステム。

【００６０】〔付記８〕　該ファイルサーバのうち少なくとも１台が、該記憶装置におけるファイルデータをキャッシュしうる主記憶部をそなえ、該主記憶部において該リクエストに応じたファイル処理を実行するキャッシュサーバとして構成されていることを特徴とする、付記５記載のストレージシステム。

〔付記９〕　該キャッシュサーバの該主記憶部が、一定期間内のリクエスト頻度が所定回数以上のファイルデータをキャッシュしておくように構成されるとともに、該リクエスト転送部が、上記のリクエスト頻度の高いファイルデータについてのリクエストを該キャッシュサーバに転送するように構成されたことを特徴とする、付記８記載のストレージシステム。

【００６１】〔付記１０〕　該リクエスト転送部が、該キャッシュサーバの該主記憶部にキャッシュされている該ファイルデータに対するリクエスト頻度が所定回数以下になると、該リクエストの転送先を該キャッシュサーバ以外のファイルサーバに変更するように構成されたことを特徴とする、付記９記載のストレージシステム。

【００６２】〔付記１１〕　該リクエスト解析部が、該リクエストを解析して当該リクエストのヘッダ部と実ファイルデータ部との境界位置を表わすヘッダオフセット値を求めるヘッダオフセット値解析部と、該ヘッダオフセット値解析部で得られた該ヘッダオフセット値を該ファイルサーバへ転送される該リクエストに付加するヘッダオフセット値付加部とをそなえていることを特徴とする、付記５記載のストレージシステム。

【００６３】〔付記１２〕　該ファイルサーバが、該リクエストに付加された該ヘッダオフセット値に基づいて該リクエストの該ヘッダ部と該データ部とをそれぞれカーネル上位層で扱われるメッセージの異なる領域にコピーするネットワークドライバをそなえていることを特徴とする、付記１１記載のストレージシステム。

〔付記１３〕　該ファイルサーバ管理ノードが、リクエスト頻度の高い特定のファイルデータについての該クライアントへの応答メッセージをキャッシュしておくキャッシュ部と、該リクエストが該特定のファイルデータについてのものであると、該キャッシュ部の該当応答メッセージを該クライアントへ返す応答部とをそなえていることを特徴とする、付記１～１２のいずれか１項に記載のストレージシステム。

【００６４】〔付記１４〕　該ファイルサーバが、異常発生時にそなえて他のファイルサーバに処理を引継ぐのに必要な情報を引継ぎ情報として該共有メモリに記録する引継ぎ情報記録部をそなえていることを特徴とする、付記３又は付記４に記載のストレージシステム。

〔付記１５〕　該ファイルサーバの異常発生を検出する異常検出部と、該異常検出部で該ファイルサーバの異常発生が検出されると、当該ファイルサーバ（以下、異常ファイルサーバという）以外の他のファイルサーバに対して該異常ファイルサーバの処理を該共有メモリの該引継ぎ情報に基づいて引継ぐよう引継ぎ指示を与える引継ぎ指示部とが設けられたことを特徴とする、付記１４記載のストレージシステム。

【００６５】〔付記１６〕　該記憶装置が、外部ノードからのアクセスを許容するように構成されたことを特徴とする、付記１～１５のいずれか１項に記載のストレージシステム。

〔付記１７〕　該ネームサーバが、外部ノードからのアクセスを許容するように構成されたことを特徴とする、付記２～１５のいずれか１項に記載のストレージシステム。

【００６６】〔付記１８〕　該ファイルサーバが、該外部ネットワークから直接受信されるリクエストに応じたファイル処理を該記憶装置に対して行なうように構成されたことを特徴とする、付記１～１７のいずれか１項に記載のストレージシステム。

【００６７】

【発明の効果】以上詳述したように、本発明のストレージシステムによれば、リクエストに応じたファイル処理を記憶装置に対して行なう複数のファイルサーバと、各ファイルサーバの処理を一元管理するファイルサーバ管理ノードと、記憶装置，ファイルサーバ及びファイルサーバ管理ノードを通信可能に相互接続する内部ネットワークとをそなえているので、必要に応じてファイルサー

バや記憶装置を簡単に増設することができ、しかも、各ファイルサーバの維持（保守）を個々に行なう必要もないので、外部ネットワークの帯域拡大に対して低コストで十分に対応できる性能・容量スケーラビリティを確保することができる。

【００６８】そして、上記の内部ネットワークに、上記の各ファイルサーバが扱うファイルデータ名を一元管理するネームサーバを接続すれば、ファイルサーバ間でファイルアクセス競合が生じることを防止することができるので、ファイル共有の信頼性向上に大きく寄与する。また、上記の内部ネットワークに、共有メモリを接続して、この共有メモリに障害発生時にそなえたファイルサーバの引継ぎ情報を随時記憶するようにしておくことで、一部のファイルサーバに障害が発生したとしても、ストレージシステムとしては正常な処理を継続することができるので、耐障害性が大幅に向上する。

【００６９】さらに、ファイルサーバ管理ノードは、過去のリクエストの転送履歴に基づいて同一ファイルデータ名のファイルデータに対するリクエストを同一ファイルサーバに転送するように構成してもよく、このようにすれば、処理速度が大幅に向上する。また、ファイルサーバの負荷を監視して負荷の低いファイルサーバにリクエストを転送するようにしてもよく、このようにすれば、各ファイルサーバに均一にリクエストを転送できるので、一部のファイルサーバに負荷が集中して障害を引き起こしてしまうようなことを確実に防止することができ、信頼性が大幅に向上する。

【００７０】さらに、リクエスト頻度が高いファイルデータについては、キャッシュサーバの主記憶部にキャッシュしておき、キャッシュサーバで処理するようにしておけば、記憶装置へのアクセス頻度を大幅に削減することができるので、さらに処理速度及び処理性能が向上する。そして、この場合、キャッシュサーバの主記憶部にキャッシュされているファイルデータに対するリクエスト頻度が所定回数以下になると、キャッシュサーバ以外のファイルサーバで処理を行なうようにすれば、リクエスト頻度の低いファイルデータがいつまでもキャッシュサーバに保持され続けることが回避されるので、キャッシュサーバの主記憶部に必要なメモリ容量を削減することができるとともに、キャッシュサーバでの処理に余裕をもたせてその処理能力を向上することができる。

【００７１】また、ファイルサーバ管理ノードにおいて、リクエストのヘッダ部と実ファイルデータ部との境界位置を表わすヘッダオフセット値を求めて、そのヘッダオフセット値をリクエストに付加してファイルサーバに転送するようにすれば、ファイルサーバのネットワークドライバにおいて、そのヘッダオフセット値に基づいてリクエストのヘッダ部とデータ部とをそれぞれカーネル上位層で扱われるメッセージの異なる領域にコピーすることができる。従って、カーネル内ゼロコピーを実現することができ、ファイルサーバの処理速度及び処理能力を大幅に向上することができる。

【００７２】さらに、上記のファイルサーバ管理ノードにおいて、リクエスト頻度の高い特定のファイルデータについてのクライアントへの応答メッセージをキャッシュしておき、受信したリクエストがそのファイルデータについてのものであると、キャッシュしておいた応答メッセージをクライアントへ返すようにすれば、ファイルサーバへリクエストを転送する必要が無いので、クライアントに対する応答速度が大幅に向上し、本システムとしての処理速度及び処理能力が飛躍的に向上することになる。

【００７３】また、上記の記憶装置は、外部ノードからのアクセスを許容するように構成してもよく、このようにすれば、他のストレージアーキテクチャとの融合が可能になる。ここで、外部ノードから上記のネームサーバへのアクセスを許容するようにすれば、上記のファイルサーバと外部ノードとのファイルアクセス調停制御を必要とせずに、外部ノードからのファイルアクセスが可能になる。

【００７４】さらに、上記のファイルサーバは、上記の外部ネットワークから直接受信されるリクエストに応じたファイル処理を記憶装置に対して行なうように構成してもよく、このようにすれば、クライアントからのファイルサーバ経由でのアクセスとファイルサーバを経由しない直接アクセスとの双方を許容することができるので、この場合も、他のストレージアーキテクチャとの融合が可能になる。

【図面の簡単な説明】

【図１】本発明の一実施形態としてのストレージシステムの構成（ストレージアーキテクチャ）を示すブロック図である。

【図２】図１に示すリダイレクタの構成を示すブロック図である。

【図３】図１に示すリダイレクタでメタ情報をキャッシュする場合を説明するためのブロック図である。

【図４】図１に示すリダイレクタでリプライメッセージを返す場合を説明するためのブロック図である。

【図５】図１に示すＮＦＳサーバ（ネームサーバ）の構成を示すブロック図である。

【図６】図１に示す共有メモリにＮＦＳサーバの引継ぎ情報をバックアップする場合を説明するためのブロック図である。

【図７】図６に示す共有メモリにバックアップされた引継ぎ情報に基づいてダウンしたＮＦＳサーバの処理を引継ぐ場合を説明するためのブロック図である。

【図８】図１に示す共有メモリにネームサーバの引継ぎ情報をバックアップする場合を説明するためのブロック図である。

【図９】図１に示すリダイレクタにおいてファイルアク

セスリクエストの境界情報を求める場合を説明するためのブロック図である。
【図１０】図１に示すＮＦＳサーバにおいて図９に示すファイルアクセスリクエストの境界情報に基づいてカーネル内ゼロコピーを実現する場合を説明するためのブロック図である。
【図１１】図１に示すＮＦＳサーバにおいて図９に示すファイルアクセスリクエストの境界情報に基づいてカーネル内ゼロコピーを実現する場合を説明するためのブロック図である。
【図１２】図９～図１１に示すファイルアクセスリクエストのフォーマット例を示す図である。
【図１３】図１に示すストレージシステムにおいて外部ノードからの二次記憶装置へのアクセスを許容する場合の構成を示すブロック図である。
【図１４】図１に示すストレージシステムにおいて外部ノードからのネームサーバへのアクセスを許容する場合の構成を示すブロック図である。
【図１５】図１に示すストレージシステムにおいて外部ノードからのリダイレクタ経由のアクセスと直接アクセスとを許容する場合の構成示すブロック図である。
【図１６】ネットワーク上での複数ノード（クライアント）間のファイル共有を実現する従来の手法を説明するためのブロック図である。
【符号の説明】
１　ストレージシステム
２　クライアント
３　外部ネットワーク（ギガビットイーサネット）
１１　リダイレクタ（Redirector；ファイルサーバ管理ノード）
１１ａ　ギガビットイーサネットカード
１１ｂ　インフィニバンドカード
１１ｃ　ネットワークプロセッサ
１１ｄ　メモリ（主記憶部）
１１ｅ　ＰＣＩ（Peripheral Component Interconnect））バス
１１ｆ　キャッシュメモリ（キャッシュ部）
１２－１～１２－ｎ　ＮＦＳ（Network File System）サーバ（ファイルサーバ）
１２′　キャッシュサーバ
１２ａ，１３ａ　ＣＰＵ（Central Processing Unit）
１２ｂ，１３ｂ　メモリ（主記憶部）
１２ｃ，１３ｃ　インタフェースカード（ＩＢ－ＩＦ）
１３　ネームサーバ
１４　高速（内部）ネットワーク〔インフィニバンド（Infiniband）〕スイッチ）
１５　共有メモリ（Shared Memory）
１５－１～１５－ｍ　メモリカード（Shared Memory Card）
１６　ＩＢ－ＦＣカード
１７　二次記憶装置
１８　ＦＣスイッチ
１９　外部ノード
２０　ネットワークディスクアダプタ
２１　ヘッダ部
２１ａ　物理レイヤヘッダ（Phy Header）
２１ｂ　ＩＰヘッダ（Internet Protocol Header）
２１ｃ　ＴＣＰヘッダ（Transmission Control Protocol Header）
２１ｄ　ＮＦＳヘッダ
２２　実ファイルデータ部
２３　ヘッダオフセット値（境界情報）
１１１　リクエスト解析部
１１１ａ　ヘッダオフセット値解析部
１１１ｂ　ヘッダオフセット値付加部
１１２　リクエスト転送部
１１３　転送履歴記録部
１１４　負荷監視部
１１５　ＮＦＳサーバ負荷監視デーモン（daemon）
１１６　応答部
１２１，１３１　引継ぎ情報記録部
１２２　ＮＩＣ（Network Interface Card）ドライバ（ネットワークドライバ）
１２３，１２４　バッファ（mbuf）
１２５　ファイルシステム部
１２６　ファイルシステムバッファ
１３２　ＮＦＳサーバ監視デーモン
１３３　ネームサーバ監視デーモン
１３４　異常検出部
１３５　引継ぎ指示部

【図１２】

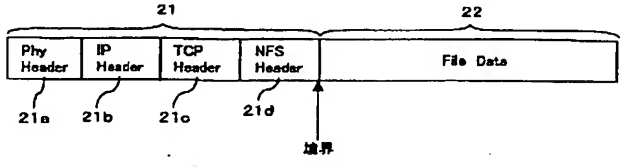

【図１】

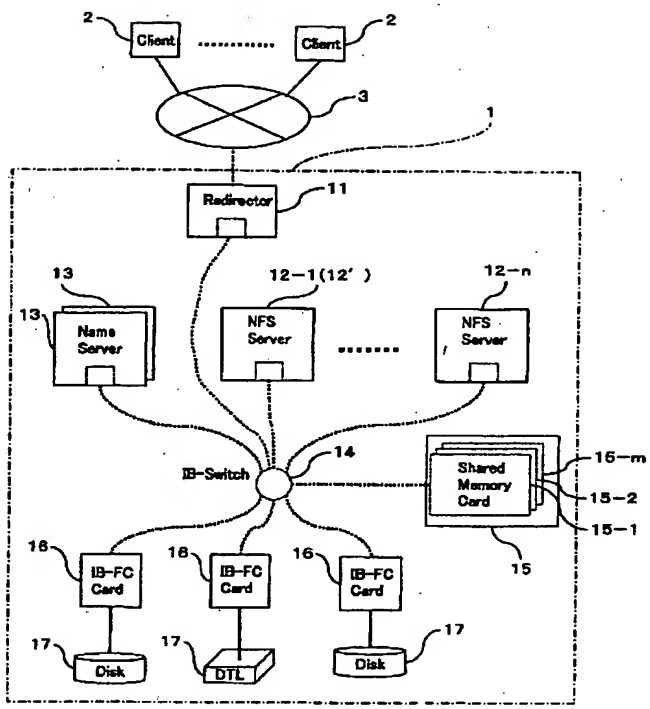
Client
Client
Redirector
Name Server
NFS Server
NFS Server
IB-Switch
Shared Memory Card
IB-FC Card
IB-FC Card
IB-FC Card
Disk
DTL
Disk

【図２】

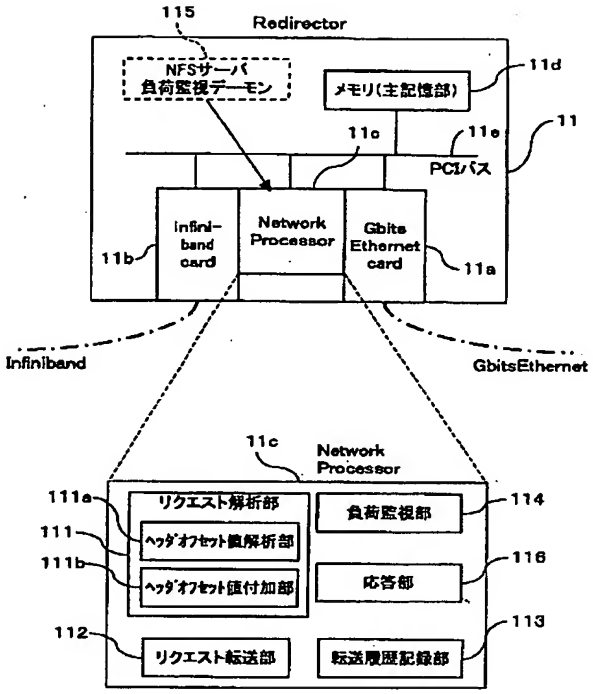
Redirector
NFSサーバ 負荷監視デーモン
メモリ(主記憶部)
PCIバス
Infini-band card
Network Processor
Gbits Ethernet card
Infiniband
GbitsEthernet
Network Processor
リクエスト解析部
ヘッダオフセット値解析部
ヘッダオフセット値付加部
リクエスト転送部
負荷監視部
応答部
転送履歴記録部

【図３】

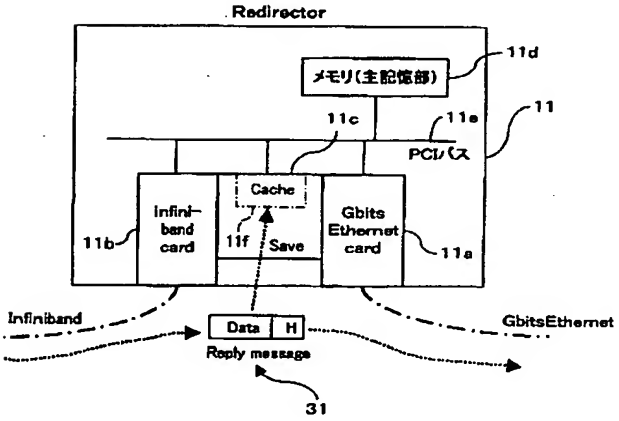
Redirector
メモリ(主記憶部)
PCIバス
Infini-band card
Cache
Save
Gbits Ethernet card
Infiniband
Data
H
Reply message
GbitsEthernet
31

【図４】

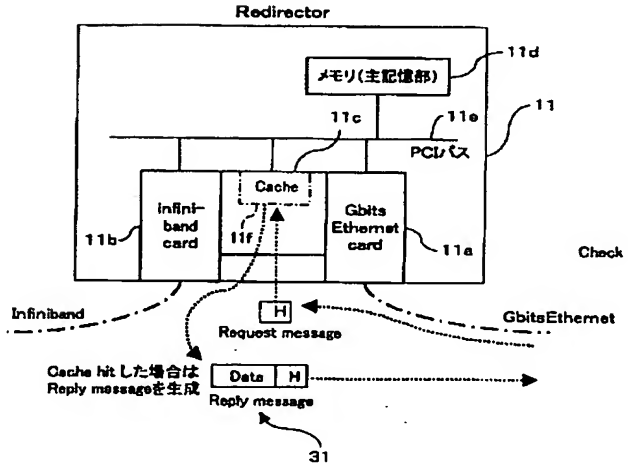
Redirector
メモリ(主記憶部)
PCIバス
Infini-band card
Cache
Gbits Ethernet card
Check
Infiniband
H
Request message
GbitsEthernet
Cache hit した場合は Reply messageを生成
Data
H
Reply message
31

【図５】

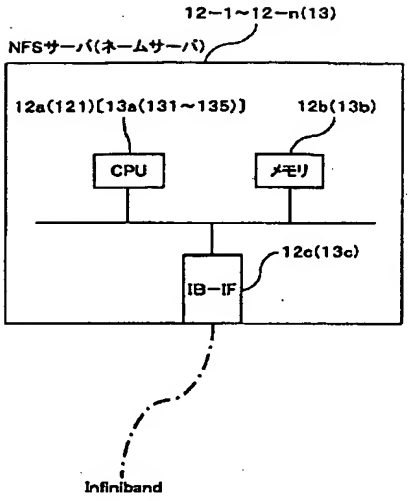

121, 131:引継ぎ情報記録部
132:NFSサーバ監視デーモン
133:ネームサーバ監視デーモン
134:異常検出部
135:引継ぎ指示部

【図６】

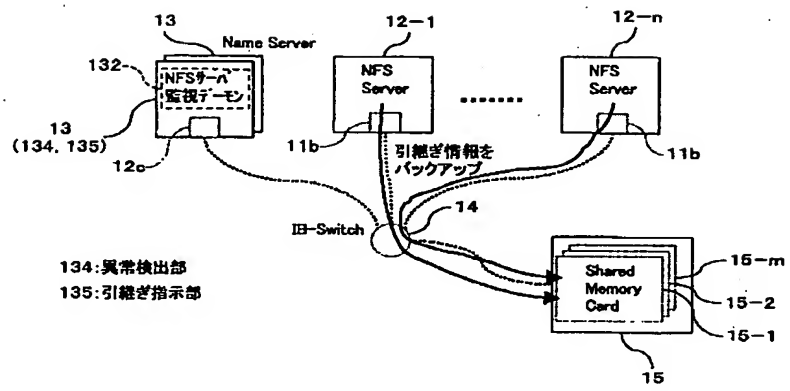

【図７】

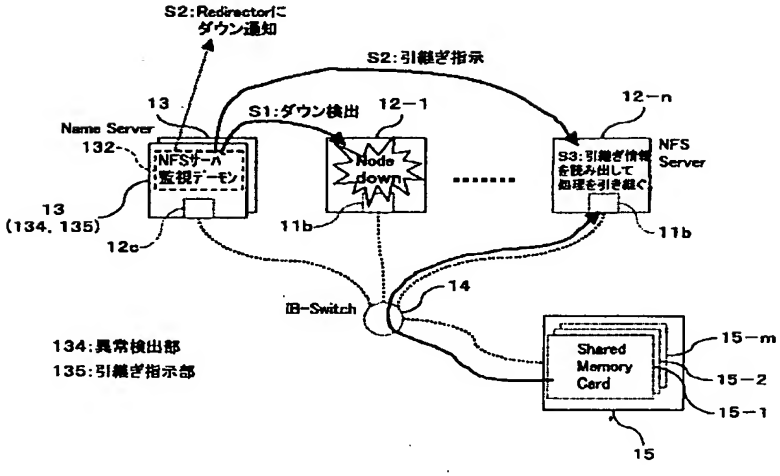

【図１０】

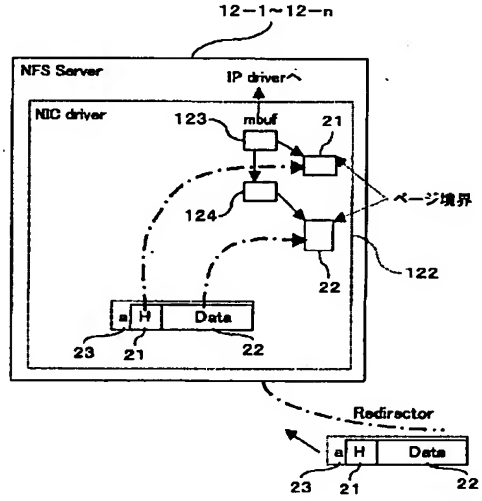

【図８】

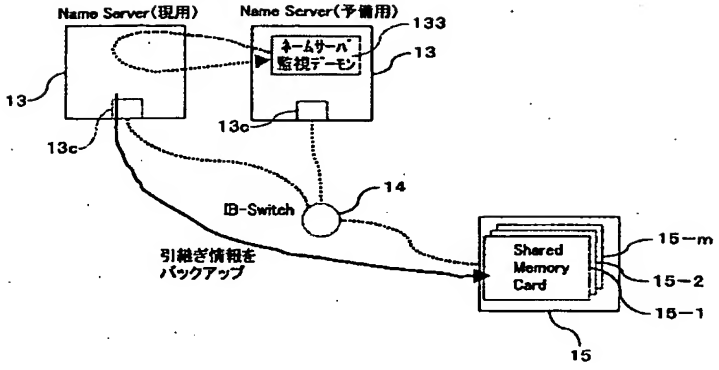
Name Server(現用)
Name Server(予備用)
ネームサーバ
監視デーモン
133
13
13
13c
13c
14
IB-Switch
引継ぎ情報を
バックアップ
Shared
Memory
Card
15−m
15−2
15−1
15

【図９】

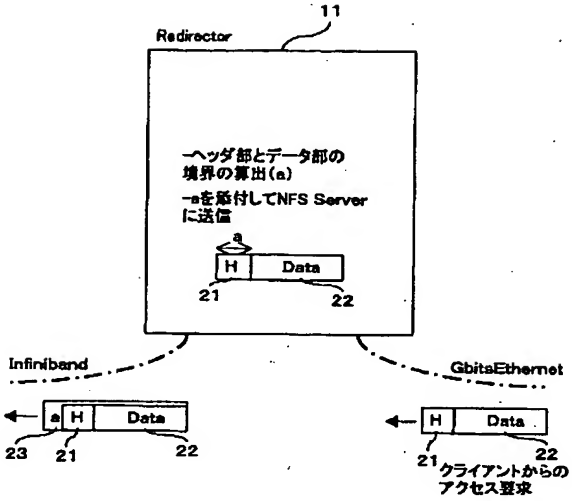
11
Redirector
−ヘッダ部とデータ部の
境界の算出(a)
−aを添付してNFS Server
に送信
a
H
Data
21
22
Infiniband
GbitsEthernet
a
H
Data
23
21
22
H
Data
21
22
クライアントからの
アクセス要求

【図１１】

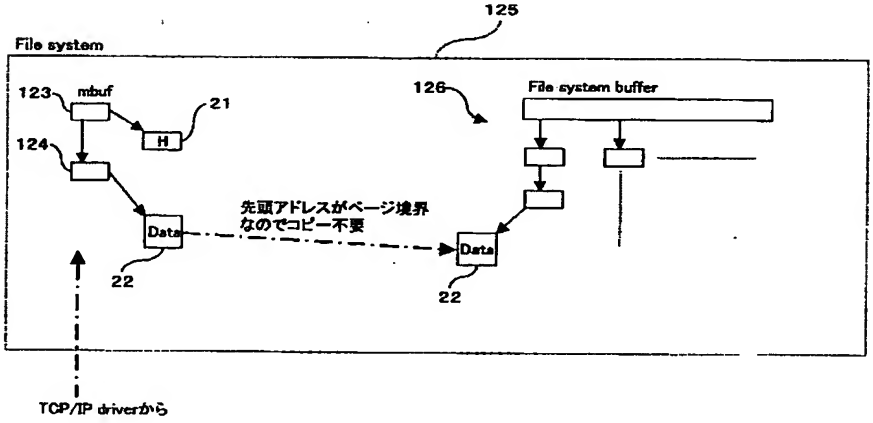
125
File system
123
mbuf
21
H
124
126
File system buffer
Data
先頭アドレスがページ境界
なのでコピー不要
Data
22
22
TCP/IP driverから

【図１６】

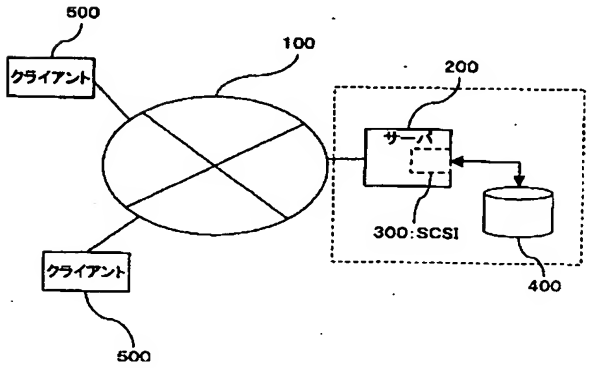
500
クライアント
100
200
サーバ
300:SCSI
400
クライアント
500

【図１３】

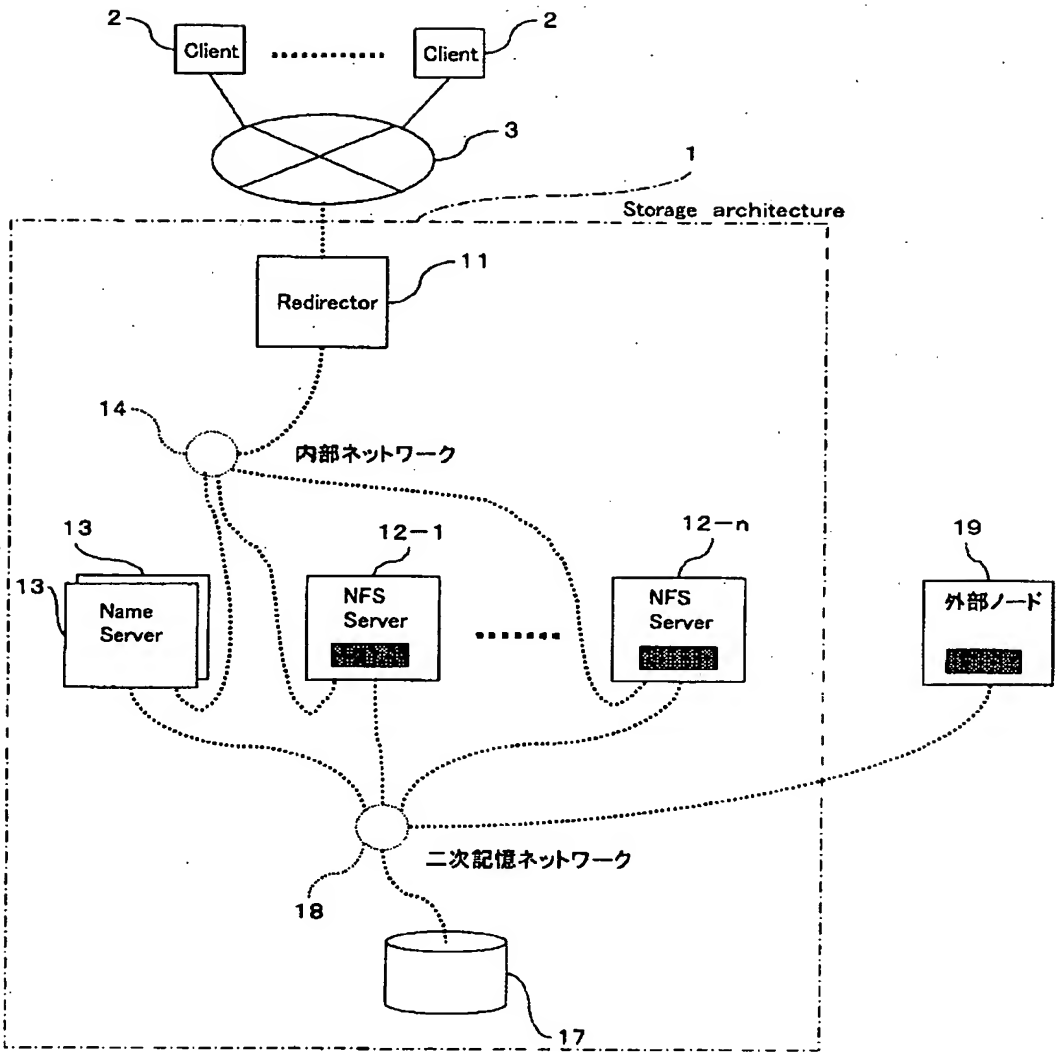
2
Client
Client
2
3
1
Storage architecture
Redirector
11
14
内部ネットワーク
13
13
Name Server
12−1
NFS Server
12−n
NFS Server
19
外部ノード
二次記憶ネットワーク
18
17

【図１４】

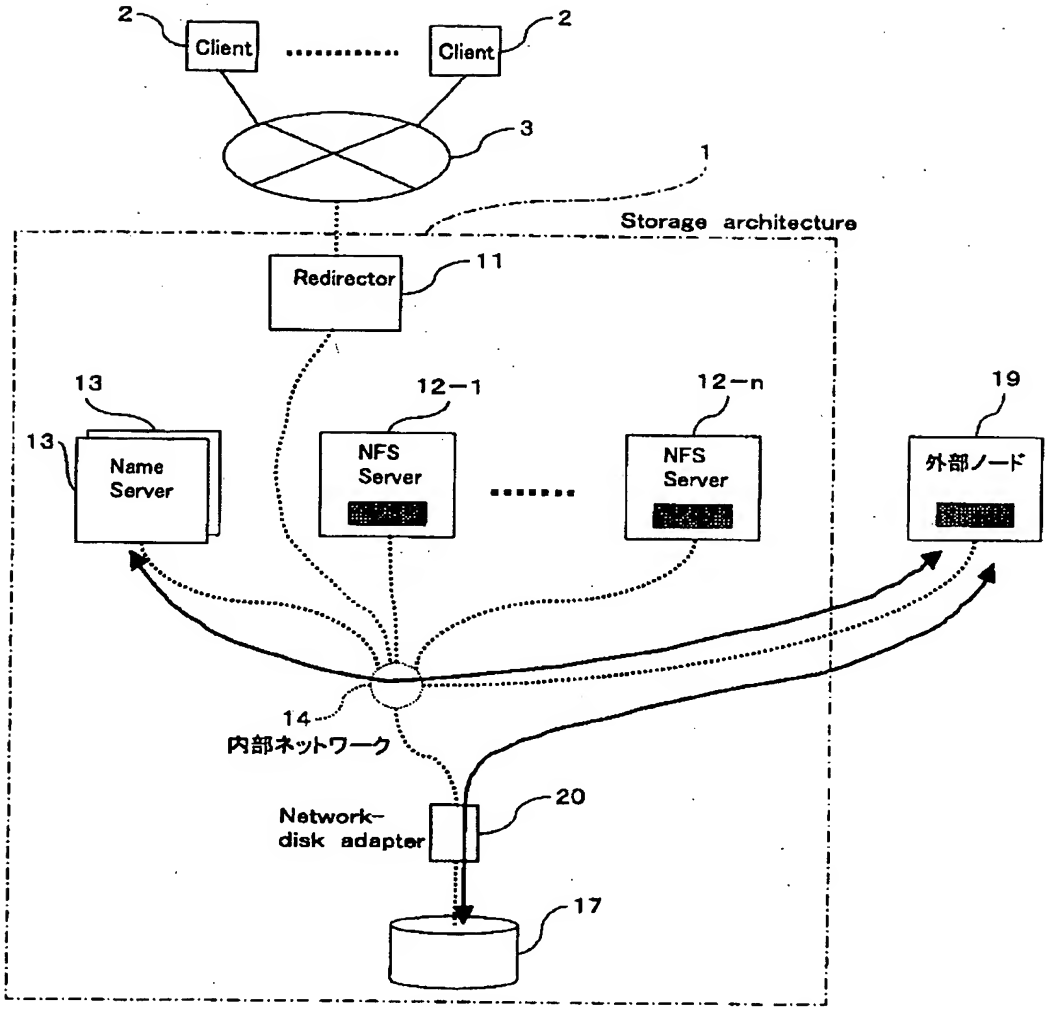
2
Client
Client
2
3
1
Storage architecture
Redirector
11
13
13
Name Server
12−1
NFS Server
12−n
NFS Server
19
外部ノード
14
内部ネットワーク
Network−disk adapter
20
17

【図１５】

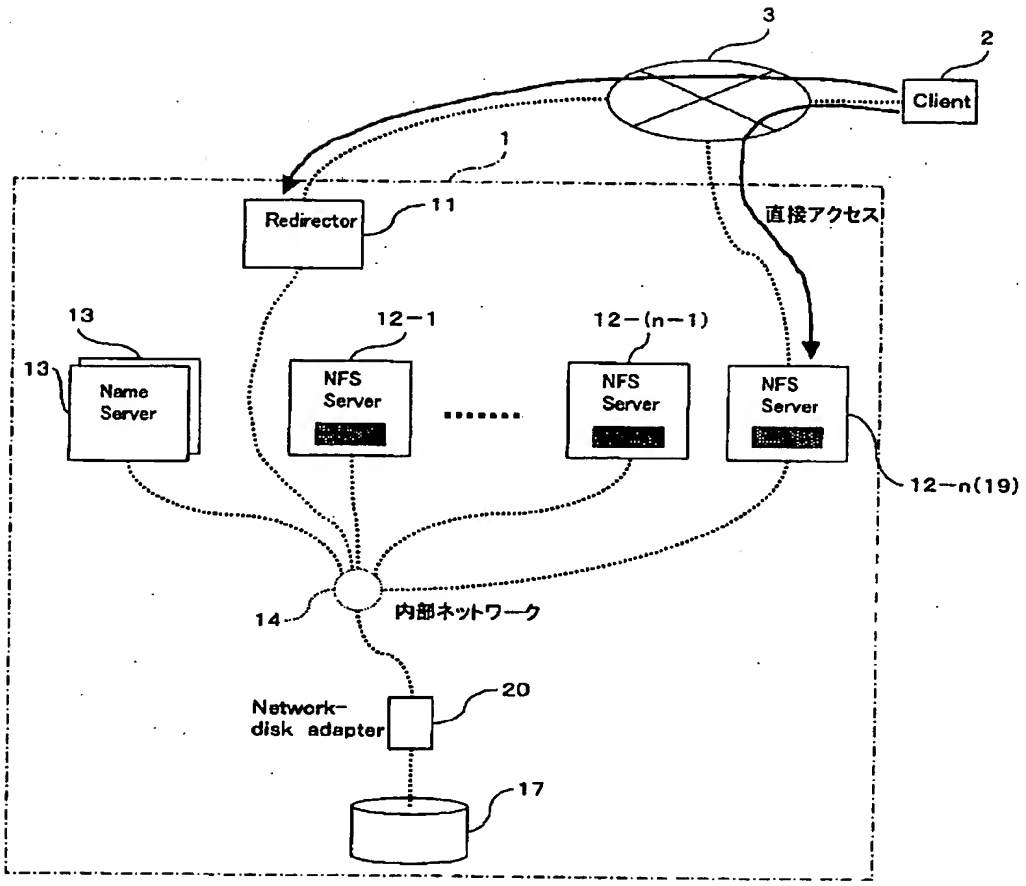
3
2
Client
1
Redirector
11
直接アクセス
13
13
Name Server
12−1
NFS Server
12−(n−1)
NFS Server
NFS Server
12−n(19)
14
内部ネットワーク
Network−disk adapter
20
17

PATENT ABSTRACTS OF JAPAN

(11)Publication number : 2001-051890
(43)Date of publication of application : 23.02.2001

(51)Int.Cl. G06F 12/00
G06F 13/00

(21)Application number : 11-226494
(22)Date of filing : 10.08.1999

(71)Applicant : TOSHIBA CORP
(72)Inventor : UCHIBORI IKUO
TAKAKUWA MASAYUKI

(54) VIRTUAL DECENTRALIZED FILE SERVER SYSTEM

(57)Abstract:
PROBLEM TO BE SOLVED: To make a client not pay attention to the number of file servers decentralized in a network and the connection states of storage devices.
SOLUTION: This virtual decentralized file server system 1 is equipped with servers 10-1 and 10-2 decentralized in the network 3 and a virtual decentralized file system 11 is decentralized and mounted on each of the servers. Modules 110-1 and 110-2 on the servers 10-1 and 10-2 which constitute this system 11 when receiving a file operation request multicast from a client 2 judge whether or not their servers are optimum servers capable of handling the request according to server information holding parts 15-1 and 15-2 holding mapping tables 14-1 and 14-2 between the virtual decentralized file system 11 and all local file systems 13-1 and 13-2 or server information on all the servers, and makes a local file system of a corresponding server perform requested file operation according to the judgement result.

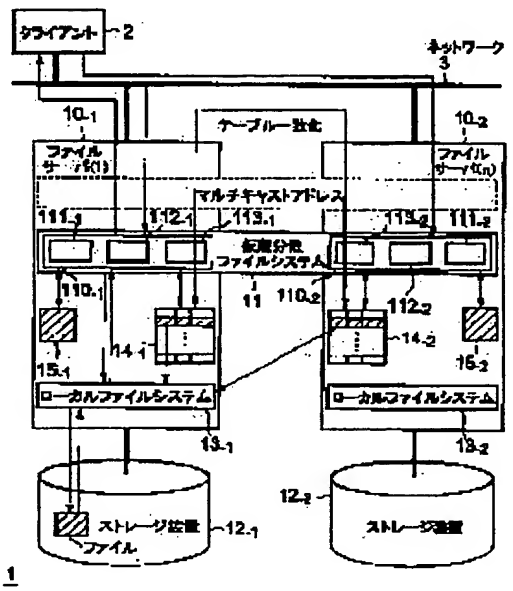

1

LEGAL STATUS

[Date of request for examination]

[Date of sending the examiner's decision of rejection]

[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]

[Date of final disposal for application]

[Patent number]

[Date of registration]

[Number of appeal against examiner's decision of rejection]

[Date of requesting appeal against examiner's decision of rejection]

[Date of extinction of right]

* NOTICES *

1. This document has been translated by computer.So the translation may not reflect the original precisely.
2. **** shows the word which can not be translated.
3.In the drawings, any words are not translated.

CLAIMS

[Claim(s)]
[Claim 1] It has the following. the aforementioned virtual distributed file system It consists of management modules formed in each aforementioned file server, respectively. each aforementioned management module By receiving in common the file manipulation demand multicasted from the client, and referring to the aforementioned mapping table of a self-server according to the demand concerned It judges whether it is the optimal server to which a self-server can process the demand concerned. The virtual distribution file server system characterized by being constituted so that the aforementioned corresponding local file system of a server may be made to perform demanded file manipulation, only when it is judged that it is the optimal server. The virtual distributed file system of not being dependent on the actual storage composition which is the virtual distribution file server system equipped with two or more file servers distributed on the network which can be multicasted, is distributed and mounted in each aforementioned file server, and manages the file of all file servers in integration. The local file system which is mounted independently in each aforementioned file server, respectively, and manages storage composition peculiar to each server. The mapping table which holds the information on mapping between the virtual distribution file server system concerned and the aforementioned local file system which actually manages the file about each file which is prepared in each aforementioned file server, respectively, and is managed in integration by the aforementioned virtual distributed file system.
[Claim 2] The virtual distribution file server system equipped with two or more file servers distributed on the network which can be multicasted characterized by providing the following. The virtual distributed file system of not being dependent on the actual storage composition which is distributed and mounted in each aforementioned file server, and manages the file of all file servers in integration. The local file system which is mounted independently in each aforementioned file server, respectively, and manages storage composition peculiar to each server. The mapping table which holds the information on mapping between the virtual distribution file server system concerned and the aforementioned local file system which actually manages the file about each file which is prepared in each aforementioned file server, respectively, and is managed in integration by the aforementioned virtual distributed file system. Either [at least] the information which is prepared in each aforementioned file server, respectively, and shows the availability of the storage equipment of the server about all the aforementioned file servers, or the information which shows the load situation of the server.
[Claim 3] The aforementioned management module is the virtual distribution file server system according to claim 1 or 2 it carries out [whether when the aforementioned file manipulation demand is a file read-out demand or a file write request, with reference to the aforementioned mapping table of a self-server, the corresponding file is under management of the aforementioned local file system of a self-server, and] whether it is the optimal server to which a self-server can process the aforementioned demand, and that it judges as the feature.
[Claim 4] It is the virtual distribution file-server system according to claim 2 characterized by to judge whether the aforementioned management module is comparing the availability of the storage equipment of the server, or the load situation of the server about each of all the

aforementioned servers with reference to the aforementioned server information maintenance means of a self-server, and is the optimal server to which a self-server can process the aforementioned demand when the aforementioned file manipulation demand is a new creation demand of a file.
[Claim 5] The aforementioned management module is a virtual distribution file server system according to claim 1 characterized by exchanging the information on the aforementioned mapping table of a self-server, and the information on the aforementioned mapping table of other servers by communication between servers in order to carry out identification of the content of the aforementioned mapping table of all the aforementioned file servers.
[Claim 6] In order that the aforementioned management module may carry out identification of the content of the aforementioned mapping table of all the aforementioned file servers While exchanging the information on the aforementioned mapping table of a self-server, and the information on the aforementioned mapping table of other servers by communication between servers, in order to carry out identification of the content of the aforementioned server information maintenance means of all the aforementioned file servers The virtual distribution file server system according to claim 2 characterized by exchanging the information on the aforementioned server information maintenance means of a self-server, and the information on the aforementioned server information maintenance means of other servers by communication between servers.
[Claim 7] It is prepared in each aforementioned file server, respectively, and a load status information maintenance means classified by file to hold the information which shows the load situation according to each file under management of the server is provided further. The aforementioned management module detects the file of the load which exceeded the 1st threshold from the information currently held at the aforementioned load status information maintenance means classified by file of a self-server. Communication between servers performs the replication of the file concerned to other arbitrary file servers. The virtual distribution file server system according to claim 1 or 2 characterized by leaving the processing to the demand concerned to a replication side when there is a read-out demand of the file concerned multicasted from the client.

[Translation done.]

* NOTICES *

1.This document has been translated by computer. So the translation may not reflect the original precisely.
2.**** shows the word which can not be translated.
3.In the drawings, any words are not translated.

DETAILED DESCRIPTION

[Detailed Description of the Invention]
[0001]
[The technical field to which invention belongs] this invention carries out cooperation operation of two or more file servers which started the file server system in a computer network system, especially were connected on the network, and relates to the virtual distribution file server system operated as a single server from a client.
[0002]
[Description of the Prior Art] Generally in today's computer network system, sharing a file between different computers connected to the network is performed. Under such environment, large-scale storage is connected to a specific computer, it applies as a file server or, recently, the system configuration of connecting the file server special-purpose machinery called NAS (Network Attached Storage) is taken in many cases.
[0003] In the environment (file server system) which uses a file server, if expandability is in a server side physically and efficiently when the storage capacity of a server runs short, it can be coped with by newly extending a disk unit etc. (storage equipment). At this time, it becomes the gestalt of using it, mounting new volume, from a client. Moreover, the server itself will be extended if the expandability of a server has reached the limitation. At this time, it becomes the gestalt of using it, mounting new volume after he is conscious of the extended server from a client.
[0004]
[Problem(s) to be Solved by the Invention] When performing file sharing in the above-mentioned computer network system using a file server, it is common that the volume composition by the side of a file server is in sight as it is from a client side. For example, when a disk unit is extended by the server side, when new volume has been recognized, you have to mount a client side. Or when the server itself is extended, the complicated work of determination or system construction, management, etc. generates the employment policy of the extended server, and the new server has been recognized also by the client side, you have to mount new volume.
[0005] Thus, in the file-sharing system (file server system) using the conventional file server, when extension of a disk unit (storage equipment) or extension of a server was required, the problem that cost great for new setup and management occurred was in all of a client side the server side. Furthermore, there was a use gestalt of storage, when only capacity wanted to extend a specific file system as it is, and it also had the case which is not solved only by extending storage equipment and a server.
[0006] this invention was made in consideration of the above-mentioned situation, and the purpose can treat from a client two or more file servers distributed on the network as a single server, and is to offer the virtual distribution file server system which does not make a client conscious of the connection state of the number of a server, or storage equipment.
[0007]
[Means for Solving the Problem] The virtual distributed file system of not being dependent on the actual storage composition which this invention is distributed and mounted in two or more file servers connected to the network which can be multicasted, and manages the file of all file servers in integration, The local file system which is mounted independently in each file server, respectively, and manages storage composition peculiar to each server, It is prepared in each aforementioned file server, respectively. about each above-mentioned file Information on mapping between a virtual distribution file server system and the local file system which actually manages the file (for example, it is managed by the virtual distribution file server system, and with the imagination path which appears from a client) While having a mapping table holding the information which matched the physical whereabouts which is managed with a local file system and is not visible from a client It is the management module in which the above-mentioned virtual distributed file system was prepared by each file server, respectively. By receiving in common the file manipulation demand multicasted from the client, and referring to the mapping table of a self-server according to the demand concerned Only when a self-server judges whether it is the optimal server which can process the demand concerned and judges that it is the optimal server, it is characterized by constituting with the management module to which the demanded file manipulation is made to perform with the corresponding local file system of a server.
[0008] The information which shows the availability of the storage equipment of the server about all file servers on each file server here, A server information maintenance means to hold the server information containing at least one side of the information which shows the load situation of the server is established further. and by each above-mentioned management module When the file manipulation demand multicasted from the client is received, it is good also as composition which judges whether it is the optimal server to which a self-server can process the demand concerned by referring to the mapping table of a self-server, or a server information maintenance means according to the demand concerned.
[0009] In such composition, the file manipulation demand multicasted without being conscious of a specific file server from a client is received in common by the management module on each file server which constitutes a virtual distribution file server system, and the mapping table of a server (self-server) which corresponds according to the demand, or a server information maintenance means is referred to. And only the only server (upper management module) which it was judged whether it is the optimal server to which a self-server can process the above-mentioned demand, and was judged to be the optimal server makes the local file system of a self-server perform demanded file manipulation as a result of this reference.
[0010] Thus, from the client of a requiring agency, he can treat two or more file servers distributed on the network as a single server, and does not need to be conscious of the connection state of the number of a server, or storage equipment.
[0011] It is good to apply either the following 1st or the 4th algorithm (the judgment technique) as an algorithm for judging whether a self-server is optimal server by the above-mentioned management module here.
[0012] The 1st algorithm is technique judged by whether the file which is applied when a file manipulation demand is a file read-out demand or a file write request, and corresponds based on the information on the mapping table of a self-server is under management of the local file system of a self-server.
[0013] The 2nd algorithm is what is applied when a file manipulation demand is a new creation demand of a file. It is based on the information on the server information maintenance means of a self-server. about each of all servers It is the technique (for example, when the availability of a self-server is the largest, the load of a self-server judges it as the above-mentioned optimal server to a low case most) judged by comparing the availability (empty storage capacity) of the storage equipment of the server, or the load situation of the server.
[0014] The 3rd algorithm is also the technique (for example, when the size of a continuation field securable on the storage equipment of a self-server is the largest, it judges as the above-mentioned optimal server) which judges by being applied when a file-manipulation demand is a new creation demand of a file, asking for a continuation field securable on the storage equipment which corresponds about each of all servers based on the information on the mapping table of a self-server, and comparing the size of the continuation field.
[0015] The 4th algorithm is also the technique judged by being applied when a file manipulation

demand is a new creation demand of a file, calculating at least two, the availability of the storage equipment of the server, the load of the server, and a continuation field securable on the storage equipment concerned. about each of all servers, and comparing the at least two information searched for as compound condition.
[0016] Even if each server receives in common the file manipulation demand multicasted without being conscious of a specific file server from a client by applying any one of the 1st of a more than, or the 4th algorithm, it can judge autonomously whether it is the optimal server for performing the demanded file manipulation for the server itself, without communicating mutually each time.
[0017] It is good to give the function (communication module) to exchange the information on the mapping table of a self-server and the information on the mapping table of other servers by communication between servers to each above-mentioned management module here, in order to carry out identification of the content of the mapping table of all file servers. Moreover, it is good to give the function to exchange the information on the server information maintenance means of a self-server and the information on the server information maintenance means of other servers by communication between servers, further to each management module (inner communication module) with the composition which was equipped with the server information maintenance means on each server in addition to the mapping table, in order to carry out identification of the content of the server information maintenance means of all file servers.
[0018] Moreover, for the identification of a mapping table, when the file organization actually managed with the local file system of a self-server is changed, it is efficient to transmit the changed information (mapping information) to all other servers by communication between servers. Similarly, for the identification of the content of a server information maintenance means, it is efficient to update the server information on a self-server periodically, and to transmit the updated server information to all other servers by communication between servers each time.
[0019] Moreover, this invention is characterized also by performing the 1st of the following [the management module of the server], or 4th processing, when a server is dynamically extended by the above-mentioned virtual distribution file server system. In the 1st processing, a lock setup which forbids renewal of a mapping table and a server information maintenance means to all other servers by communication between servers is performed. first, in the following processing of the 2nd The content of a mapping table server information maintenance means is copied to a self-server from other arbitrary servers by communication between servers. in the following processing of the 3rd The server information on a self-server is added to the server information maintenance means of a self-server. in the following processing of the 4th - BA information on a self-server is made to reflect in the server information maintenance means of all other servers by communication between servers, identification of the server information maintenance means of all servers is attained, and the above-mentioned lock setup is canceled after an appropriate time.
[0020] The number of a server is dynamically extensible with a series of operation at the time of such server extension. And a client can use the extended server, without being conscious of extension of the number of a server.
[0021] Moreover, this invention adds a load status information maintenance means classified by file to hold the information which shows the load situation according to each file under management of the server to each file server, and sets it to the management module of each server. The file of the load which exceeded the 1st threshold from the information currently held at the load status information maintenance means classified by file of a self-server is detected. Communication between servers performs the replication of the file concerned to other arbitrary file servers. When there is a read-out demand of the file concerned multicasted from the client, it is characterized also by leaving the processing to the demand concerned to a replication side.
[0022] In such composition, an autonomous load distribution becomes possible. Here, an autonomous load distribution can carry out to a large area more effectively by communication between servers performing the replication of the file concerned to other arbitrary file servers, when the file which carried out [above-mentioned] detection is a file by which the replication

was carried out, and leaving the processing to the demand concerned to a new replication side, when there is a read-out demand of the file concerned multicasted from the client. Moreover, when the load of a file set as the object of the replication to other servers consists of the 1st threshold of the above below the threshold of a low 2nd Elimination of the file which corresponds by communication between servers to the other servers concerned from the management module on the server which performed the replication is required. When there is a read-out demand of the file concerned multicasted from the client, and self performs processing to the demand concerned, a dynamic load distribution becomes possible.
[0023] Now, it is possible the communication between servers for the above-mentioned identification (communication of mapping information or server information) and to use the above-mentioned network for communication between servers for the above-mentioned replication further. However, it is good to consider as the composition which forms the channel (private channel) of the exclusive use which interconnects each file server independently of the above-mentioned network, and performs communication between servers using the channel concerned. In this case, it can prevent that the throughput of a network gets worse for communication between servers.
[0024] Moreover, this invention is characterized also by performing the above-mentioned communication between servers by each above-mentioned management module through the interface concerned while it is further equipped with the interface in which the multi-host who interconnects the storage equipment of each file server and the server concerned is possible.
[0025] In such composition, since each above-mentioned storage equipment is shared between each server with the above-mentioned interface and communication between servers for the replication of the communication between servers for the above-mentioned identification and a still more dynamic file is performed through the above-mentioned interface, an autonomous load distribution is realized effectively.
[0026] In addition, this invention is materialized also as invention concerning a method.
[0027]
[Embodiments of the Invention] Hereafter, with reference to a drawing, it explains per gestalt of operation of this invention.
[0028] [Operation gestalt of ** 1st] drawing 1 is the block diagram showing the composition of the computer network system which applies the virtual distribution file server system concerning the 1st operation gestalt of this invention.
[0029] In this drawing, it is the client (client computer) as which 1 requires a virtual distribution file server system of this file server system 1, and 2 requires file service of it. The virtual distribution file server system 1 is realized using the plurality (two sets of for example, file servers) (server computer) 10-1 distributed on the network 3, and 10-2. In addition, drawing, although only one set is shown for convenience, as for a client 2, it is common that more than one exist.
[0030] 11 is a virtual distributed file system which makes the center of the virtual distribution file server system 1, and is distributed and mounted in each file server 10-1 and 10-2. this virtual distributed file system 11 -- all the file servers 10-1 and the file of 10-2 -- integration --like -- managing -- a file server 10-1 and 10-2 -- each actual volume composition (storage composition) is provided with the imagination file system for which it does not depend to a client 2
[0031] The virtual distributed file system 11 has each file server 10-1 and the virtual distribution file module 110-1,110-2 distributed and mounted in 10-2. The virtual distribution file module 110-1,110-2 is a management module for showing as one file system virtually to a client 2, distributing and processing the demand from a client 2 on a file server 10-1 and 10-2. The virtual distribution file module 110-1,110-2 The virtual distribution file interface 111-1,111-2 which processes nothing and the demand from a client 2 for the center of the module 110-1,110-2 concerned, The local file system 13-1 mentioned later and the interface 112-1,112-2 of 13-2 (local file interface), It has the communication module 113-1,113-2 which performs communication (communication between servers represented by the communication for the identification of the mapping table 14-1 mentioned later, the information on 14-2, and server

information) between the module 110-1,110-2 concerned.
[0032] A file server 10-1 and 10-2 are connected with the client 2 through the network 3. A file server 10-1 and 10-2 mount the storage equipments 12-1, such as a disk unit connected to the server 10-1 concerned and 10-2 other than the virtual distributed file system 11, the local file system (local file system) 13-1 which manages 12-2 (actual storage composition), and 13-2, respectively.
[0033] The virtual distributed file system 11, the local file system 13-1, the mapping table 14-1 of the same content which matches 13-2, and 14-2 are prepared in a file server 10-1 and 10-2. The data structure of this table 14-i (1 i= 2) is shown in drawing 2 .
[0034] The registration field 141 of the file name of a file where the virtual distributed file system 1 manages each entry of table 14-i (file name field), The logical whereabouts on the virtual distributed file system 1 of the file concerned Express. A path (It is visible from a client 2) The registration field of a (virtual path) (Virtual path field) 142, the registration field (whereabouts positional information field) 143 of the whereabouts positional information showing the physical whereabouts position on the storage of the file concerned (it is not visible from a client 2), and the access privilege (permission/prohibition) to the file concerned It has the registration field (permission information field) 144 of the permission information for managing, and the registration field 145 of other various attributes.
[0035] the virtual distributed file system 11 (upper virtual distribution file module 110-i) refers to mapping table 14-i of such a data structure -- for example, in a file server 10-1 and any of 10-2 a certain file's being and whereabouts information can be acquired, and also a permission etc. can acquire the attribute of a file if needed
[0036] The server information attaching part 15-1 of the same content and 15-2 are further prepared in a file server 10-1 and 10-2. Server information attaching part 15-i (1 i= 2) is used for holding server information including all the file servers 10-1 that constitute the virtual distribution file server system 1, the information (resource information) which shows the empty storage capacity (storage equipment 12-1 and 12-2) of 10-2, and the information which shows a load situation as shown in drawing 3 .
[0037] Next, operation of the composition of drawing 1 is explained. With this operation gestalt, it seems that each file server 10-1, the local file system 13-1 of 10-2, and not 13-2 but the virtual distributed file system 11 is mounted from the client 2. Then, a client 2 publishes the same demand to all the file servers 10-1 in which the virtual distributed file system 11 is mounted, and 10-2, when a certain file manipulation demand occurs. According to the technique of using IP (Internet Protocol) multicasting in this case, issue of a demand is possible for a client 2 side, without being conscious of the number of a file server.
[0038] A file server 10-1 and 10-2 will pass the demand concerned to the virtual distribution file module 110-1,110-2 corresponding to the self-server in the virtual distributed file system 11, if the demand from a client 2 is received. Then, a module 110-1,110-2 (inner virtual distribution file interface 111-1,111-2) is the read-out demand or the creation demand which it writes in (updating), and is a demand or is a creation demand or directory of a new file the demand of whose is a file, or distinguishes the demand classification.
[0039] Here, the file manipulation demand from a client 2 shall be a read-out demand or write request of a file. The file name of the file set as the object of a demand and the path on the virtual distributed file system 11 of the file concerned (virtual path) are given to this demand.
[0040] The virtual distribution file module 110-1,110-2 (inner virtual distribution file interface 111-1,111-2) When the file manipulation demand from a client 2 is a read-out demand or write request of a file, The file name and virtual path of a file which were demanded refer the mapping table 14-1 in a self-server, and 14-2. It investigates whether the file with the operation demand is held in the self-server (the storage equipment 12-1 connected to the self-server, 12-2) from the registration information on the table 14-1 with a file name and a virtual path concerned, and the whereabouts positional information field 143 in the entry in 14-2.
[0041] When the demanded file is held in the self-server, the virtual distribution file module 110-1,110-2 (inner virtual distribution file interface 111-1,111-2) accesses an actual file through the local file system 13-1 in a self-server, and 13-2 with the local file interface 112-1,112-2, and

returns a response to a client 2. On the other hand, when there is no file with the operation demand into a self-server, it is regarded as what other servers answer, and does not answer.
[0042] On the other hand, when the demand from a client 2 is creation of a new file, or creation of a directory, refer to the server (not being mapping table 14-1 and 14-2) information attaching part 15-1 and 15-2 for the virtual distribution file module 110-1,110-2. And according to a predetermined algorithm, only virtual distribution file module 110-i on [of any one] server 10-i (i is 1 or 2) receives the demand from a client 2 by virtual distribution file interface 111-i based on the server information on the server information attaching part 15-1 and all the servers currently held 15-2. Specifically, virtual distribution file module 110-i on server 10-i shall receive the demand from a client 2, when the empty storage capacity which the server information on all servers shows is measured and it can be judged with the empty storage capacity of self-server 10-i (storage equipment 12-i) being the largest. In this case, it is not necessary to necessarily give the information on a load situation into server information.
[0043] In addition, the load which the server information on all servers shows is compared, and you may make it the load of a self-server receive the demand from a client 2 to a low case most. In this case, it is not necessary to necessarily give the information on the empty storage capacity of a server [be / under / server information / correspondence / it].
[0044] In addition, it asks for each storage equipment 12-1 and a continuation field securable on 12-2 from the mapping information for every file of mapping table 14-i (from the operating condition of jamming each storage equipment 12-1 and the field of 12-2), and when storage equipment with the largest size is storage equipment 12-i of a self-server, you may make it for the continuation field more than required size to be securable, and receive the demand from a client 2. In this case, the server information attaching part 15-1 and 15-2 are not necessarily required.
[0045] Furthermore, it is good as for a method of judgment in whether it is the optimal server to which is asked for an evaluation value by making at least two of the sizes of empty storage capacity, a load situation, and a securable continuation field into conditions (compound condition), and a self-server receives a demand.
[0046] Now, in virtual distribution file module 110-i on file server 10-i, if the demand from a client 2 is received by virtual distribution file interface 111-i, local file system 13-i will perform creation of the demanded new file, or creation of a directory through local file interface 112-i, and the mapping table 14-1 and the entry information applicable to 14-2 will be registered.
[0047] After creation of a new file or creation of a directory is completed, in virtual distribution file module 110-i on file server 10-i, the new entry information registered into mapping table 14-i on a self-server is sent to virtual distribution file module 110-j on all other server 10-j (j is 1 or 2, however j!=i) through a network 3 by communication-module 113-i. Virtual distribution file module 110-j (inner virtual distribution file interface 111-j) receives the entry information on mapping table 14-i sent from virtual distribution file module 110-i through communication-module 113-j. And module 110-j (inner interface 111-j) received, and also registers the entry information of mapping table 14-i on server 10-i into mapping table 14-j in a self-server. Thus, the virtual distribution file module 110-1,110-2 on file server 10-1,110-2 can attain identification of the mapping table 14-1 concerned and the content of 14-2 by exchanging mutually the mapping table 14-1 and the entry information (entry information updated further) for which 14-2 was newly registered.
[0048] Moreover, a file server 10-1 and the virtual distribution file module 110-1,110-2 on 10-2 While updating periodically the server information on a self-server (empty storage capacity and load situation) among the server information attaching part 15-1 on a self-server, and the server information on each server currently held 15-2 By sending the updated server information to all other servers (upper virtual distribution file module 110-2,110-1) periodically through a network 3 (communication module 113-1,113-2) Identification of each file server 10-1, the server information attaching part 15-1 of 10-2, and the content of 15-2 is attained. That is, the virtual distribution file module 110-1,110-2 attains identification by exchanging server information mutually periodically.
[0049] By the above operation, distribution / cooperation operation of a file server 10-1 and 10-

2 can be carried out autonomously, and an imagination file server can be offered, without a file server making a client 2 in fact conscious of two sets (two or more sets) of a certain thing.
[0050] In addition, although the example of the system of drawing 1 explained the case where the number of servers was two, even if a server is three or more sets, an imagination file server can be offered according to the same structure.
[0051] [Operation gestalt of ** 2nd] drawing 4 is the block diagram showing the composition of the computer network system which applies the virtual distribution file server system concerning the 2nd operation gestalt of this invention, and has given the same sign to the same portion as drawing 1 .
[0052] In drawing 4 , the virtual distributed file system 41 which makes the center of the virtual distribution file server system 4 is distributed and mounted in n sets of file servers 10-1 -, and 10-n. this virtual distributed file system 41 -- the virtual distributed file system 11 in drawing 1 - - the same -- the file of all the file servers 10-1 - 10-n -- integration ---like -- managing -- each file server 10-1 - 10-n -- each actual volume composition is provided with the imagination file system for which it does not depend to a client 2 The virtual distributed file system 41 has the virtual distribution file module 410-1 which processes the demand from a client 2 on each file server 10-1 - 10-n - 410-n. A module 410-1 - 410-n have the virtual distribution file interface 411-1 which is the same composition as the module 110-1,110-2 in drawing 1 - 411-n, the local file interface 412-1 - 412-n, and a communication module 413-1 - 413-n. However, the communication module 413-1 in this operation gestalt - 413-n are constituted so that it may communicate through the private channel 5 mentioned later unlike the communication module 113-1,113-2 in drawing 1 .
[0053] A file server 10-1 - 10-n are connected with the client 2 through the network 3. A file server 10-1 - 10-n mount the local file system (local file system) 13-1 to 13-2 which manages the storage equipment 12-1 to 12-2 connected to the server 10-1 concerned - 10-n other than the virtual distributed file system 11, respectively. The mapping table 14-1 - 14-n, and the server information attaching part 15-1 to 15-2 are formed in a file server 10-1 - 10-n.
[0054] n sets of the point that the number of the file server from which the feature of the virtual distribution file server system 4 of the composition of drawing 4 constitutes a system unlike the virtual distribution file server system 1 of the composition of drawing 1 is n sets, and its file servers 10-1 -, and 10-n are the points by which interconnection is carried out also with private channel 5 with an another network 3. This private channel 5 is not specified about a physical layer, although it is Ethernet or a fiber channel (Fibre Channnel). Moreover, you may be a loop and a switch although the bus type is assumed in the example of drawing 4 also about topology.
[0055] In the composition of drawing 4 , in order for a file server 10-1 - 10-n to perform distribution / cooperation operation (the virtual distribution file module 410-1 in the virtual distributed file system 41 - 410-n) It is necessary to make the contents of the mapping table 14-1 - 14-n, and the server information attaching part 15-1 - 15-n always coincidence-ize among each server 10-1 - 10-n so that it may be guessed from explanation of operation with the operation form of the above 1st. However, when the number of the file server which constitutes the virtual distribution file server system 4 increases, the traffic (communication between servers of a sake) of the formation of information coincidence increases, and the throughput on a network 3 is made to get worse in performing information coincidence-ization between server 10-1 - 10-n through a network 3 like the operation form of the above 1st.
[0056] Then, with this operation gestalt (2nd operation gestalt), the private channel 5 only for [between servers] information interchange is formed like the composition of drawing 4 among each file server 10-1 - 10-n. To the communication between servers performed by a communication module 413-1 - 413-n by the virtual distribution file module 410-1 in the virtual distributed file system 41 - 410-n That is, it is made to use this channel 5 for the communication between servers for carrying out identification of the content of the mapping table 14-1 - 14-n, and the server information attaching part 15-1 - 15-n.
[0057] Thus, with this operation gestalt, mitigation of the load of a network 3 can be aimed at by not being a network 3 and using the private channel 5 for the communication between servers for the identification of the content of the mapping table 14-1 - 14-n, and the server information attaching part 15-1 - 15-n.

[0058] The 1st and 2nd operation gestalt described beyond [the 3rd operation gestalt] showed the example of the virtual distribution file server structure of a system which carries out distribution / cooperation operation of two or more file servers. The composition of this 1st [the], drawing 1 referred to with the 2nd operation gestalt, and drawing 4 is a static example in the specific number of a server. However, about the number of a server, considering as the composition which can be changed is desirable.
[0059] Then, the number of a server which constitutes a virtual distribution file server system is explained with reference to a drawing about the 3rd operation gestalt of this invention made dynamically extensible. Drawing 5 is the block diagram showing the composition of the computer network system which applies the virtual distribution file server system concerning the 3rd operation gestalt of this invention, and has given the same sign to the same portion as drawing 4 .
[0060] First, as shown in drawing 5 (a), new file server 10- (n+1) shall be added to the virtual distribution file server system 4 4 shown in drawing 4 , i.e., the virtual distribution file server system which consists of n sets of file servers 10-1 -, and 10-n.
[0061] In this case, virtual distribution file module 410- (n+1) on the virtual distributed file system 41 currently distributed by added file server 10- (n+1) To the file server 10-1 which already constitutes the virtual distribution file server system 4 - 10-n, as a sign A1 shows drawing 5 (a) (For example, the private channel which is not illustrated is minded) By communication between servers, renewal of the entry information on the mapping table 14-1 - 14-n and the server information on the server information attaching part 15-1 - 15-n (the resource information and load situation of each server are included) is locked.
[0062] Module 410- (n+1) on server 10- (n+1) moreover added As a sign A2 shows drawing 5 (b), from the server 10-1 of the either other file servers 10-1 or - the 10-n, for example, a file server All the information on the mapping table 14-1 and the server information attaching part 15-1 is copied to mapping table 14- in a self-server (n+1), and server information attaching part 15- (n+1) by communication between servers.
[0063] Next, to server information attaching part 15- after a copy (n+1), module 410- (n+1) on added file server 10- (n+1) adds the server information which shows the resource and load situation of a self-server, as a sign A3 shows drawing 5 (c).
[0064] After an appropriate time, as a sign A4 shows drawing 5 (d), module 410- (n+1) on file server 10- (n+1) publishes an identification demand of server information to all other file servers 10-1 - 10-n by communication between servers after an appropriate time, and cancels a lock after that.
[0065] By a series of above operation, a firewood shelf server (file server 10- (n+1)) can be dynamically added to the virtual distribution file server system 4 already built. If the information how a new resource is distributed to the volume composition of the present virtual distribution file server system 4 in this case is added, it is also possible to extend volume alternatively if needed.
[0066] [Operation gestalt of ** 4th] drawing 6 is the block diagram showing the composition of the computer network system which applies the virtual distribution file server system concerning the 4th operation gestalt of this invention, and has given the same sign to the same portion as drawing 4 .
[0067] In drawing 6 , 6 is a virtual distribution file server system equivalent to the virtual distribution file server system 4 in drawing 4 . The feature of this virtual distribution file server system 6 is equipped with the load status information attaching part 16-1 classified by file holding the information (load status information classified by file) on the load situation about each file currently held at the self-server (storage equipment 12-1 - 12-n) - 16-n in the file server 10-1 which constitutes the system 6 concerned - 10-n. In connection with this, the functions which the virtual distributed file system 61 which makes the center of the virtual distribution file server system 6 has also differ in part in the virtual distributed file system 41 in drawing 4 . However, the same sign (410-1 - 410-n) as drawing 4 is used for the virtual distribution file module of each file server 10-1 in the virtual distributed file system 61 - every

10-n for convenience. In addition, in drawing 6 , the component in a module 410-1 - 410-n (a virtual distribution file interface, a local file interface, communication module) and the mapping table on a file server 10-1 - 10-n, and the server information attaching part are omitted.
[0068] Load status information attaching part 16classified by file-i (i=1-n) has the data structure shown in drawing 7 (a), and holds the load status information classified by file containing the information which shows the load situation for every file in a self-server, the information (file attribute) which shows the attribute of the file, and a replication flag. It is shown whether the corresponding file of a file attribute is original or it is a replica (duplicate). Moreover, a replication flag shows whether it is whether it being generation ending about the replica at another servers side, and replication ending that is, when a corresponding flag is original.
[0069] Signs that the replica 612 of the arbitrary files 611 in the storage equipment 12-1 which a file server 10-1 has in storage equipment 12-n which file server 10-n has is held by the replication B1 are shown in drawing 6 .
[0070] Next, operation of the composition of drawing 6 is explained. Refer to the load status information attaching part 16-1 classified by file - the 16-n for each virtual distribution file module 410-1 on the virtual distributed file system 61 - 410-n periodically, for example. And a module 410-1 - 410-n From the load status information according to file currently held at an attaching part 16-1 - 16-n In the file currently held at the self-server (storage equipment 12-1 -. 12-n) When it is detected that the file of the load beyond the 1st threshold exists, communication between servers through the private channel 5 performs replication operation which generates asynchronously the replica of a file which corresponds to one of the other servers. The load situation of a file is total of the number of demands in the queue (queue) of the demand to the file concerned, or the size which the demand in the waiting state of the file concerned shows, and whenever it finishes processing a demand as whenever it receives a demand, it is updated here. Moreover, based on the server information currently held at the server information attaching part which is not illustrated, a load should just choose a low server as the object server of a replication most.
[0071] The virtual distribution file module 410-1 - 410-n will set to a notice state [finishing / a replication] the replication flag in the load status information of the corresponding file currently held at the load status information attaching part 16-1 classified by file of a self-server - 16-n, if replication operation is performed. Moreover, the virtual distribution file module of a server set as the object of replication operation adds the load status information of a replica [in the load status information attaching part classified by file of a self-server].
[0072] Here, as shown in drawing 6 , the replication B1 of the file 611 which a file server 10-1 holds should be performed to file server 10-n through the private channel 5, and the replica 612 should be held at storage equipment 12-[of the file server 10-n concerned] n. In this case, the replication flag in the load status information of the file 611 currently held at the load status information attaching part 16-1 classified by file of a file server 10-1 is set to the state which shows replication ending. Moreover, the new load status information about the replica 612 of a file 611 is added to load status information attaching part 16classified by file-[of file server 10-n] n. The file attribute in this load status information shows that a corresponding file is a replica (file 611) (612).
[0073] Henceforth, when there is a new read-out demand of a file 611 from a client 2, if the file server 10-1 (virtual distribution file module 410-1) holding the file 611 concerned investigated whether the load of the file 611 concerned would be over the 2nd threshold (however, the 2nd threshold < 1st threshold) and has exceeded, it will not answer a demand from a client 2. In this case, to the demand from a client 2, file server 10-n which received the replication answers. File server 10-n does not need to take into consideration whether a file server 10-1 answers, and as long as it has the replica 612 of the demanded file 611, it should just answer a client 2 here.
[0074] Thus, by file server 10-n processing the new read-out demand to the file 611 from a client 2 using the replica 612, by the file server 10-1 holding the file 611, processing of the read-out demand to the file 611 concerned received before it progresses, and the load of the file 611 concerned becomes below the threshold of the above 2nd. Then, the virtual distribution file module 410-1 on a file server 10-1 sends the demand for eliminating the replica 612 of a file 611

by communication between servers through the private channel 5 to virtual distribution file module 410-n on file server 10-n.
[0075] Virtual distribution file module 410-n on file server 10-n which received this demand processes using a replica 612 only to a received demand already, and eliminates the load status information corresponding to after an appropriate time with a replica 612. On the other hand, if the virtual distribution file module 410-1 on a file server 10-1 has the new read-out demand to the file 611 from a client 2, it will answer to it.
[0076] By the way, as a result of coming to receive the read-out demand to the file 611 concerned by file server 10-n, before the load of the file 611 in a file server 10-1 becomes below the 2nd threshold by the replication of the file 611 from a file server 10-1 to file server 10-n, the load of the replica 612 of the file 611 concerned in file server 10-n can exceed the 1st threshold.
[0077] Then, what is necessary is for file server 10-n to generate the next generation's replica to other one server using a replica 612 shortly, namely, to perform the replication of a replication, and just to make the read-out demand to a file 611 process by the server in such a case. for that purpose, a load situation and a replication flag as shown in the load status information for every file held at load status information attaching part 16classified by file-i (i=1-n) at drawing 7 (a) -- in addition, as shown in drawing 7 (b), it is good to give the generation information on a file
[0078] In this case, when the load of a certain generation's replica falls below in the threshold of the above 2nd, it is controllable to eliminate the replica of the next generation which the server set as the object of the replication by the server has from a server with the replica concerned etc. the case where the server as which elimination of a replica was required is generating the replica of the next generation further to another server at this time -- the -- it is good to eliminate the replica of the next generation further In addition, you may make it the server in which a load has a low file most answer the read-out demand to the file concerned about the same file (for a replica to be included) by attaining identification between each server at least like the server information described above about the load status information of the file relevant to the replica.
[0079] recently -- streaming data, such as video and an audio, -- or the contents of WWW (World Wide Web) etc. have fundamentally main read-out, its size is comparatively large, and the data which need a certain amount of response (it is a band guarantee depending on the case) are increasing them And since the case which looks at in the short term and access concentrates on specific data (file) is assumed, such data may be difficult to secure a response. The composition of drawing 6 described above is a thing supposing such a situation, and when access concentrates on a specific file, it enables it to distribute access of the FAIRUHE concerned by performing REBURIKESHON of the file concerned automatically. Not only a load distribution but this composition can be used for backup of the high file of importance.
[0080] [Operation gestalt of ** 5th] drawing 8 is the block diagram showing the composition of the computer network system which applies the virtual distribution file server system concerning the 5th operation gestalt of this invention, and has given the same sign to the same portion as drawing 4 .
[0081] In drawing 8 , 8 is a virtual distribution file server system equivalent to the virtual distribution file server system 4 in drawing 4 . The interconnection of a file server 10-1 - 10-n, and storage equipment 12-1 - 12-n is carried out by FC-AL (Fibre Channnel Arbitrated Loop)80, and the feature of this virtual distribution file server system 8 is that it has applied the network configuration (that is, a multi-host is possible) which can share storage equipment (as a target) 12-1 - 12-n from each file server (as a host) 10-1 - 10-n. Here, unlike the composition of drawing 4 , be careful of a point without the private channel 5.
[0082] What is necessary is just to perform communication between servers performed through the private channel 5 in the composition of drawing 4 (the communication module 413-1 of the virtual distribution file module 410-1 - 410-n - 413-n) through a network 3 with the composition of this drawing 8 like the composition of drawing 1 (as for drawing, this state is shown). Moreover, you may be made to perform the above-mentioned communication between servers

on FC-AL80 through the interface for storage connection of a file server 10-1 - 10-n. In this case, the load of a network 3 is mitigable the same with having used the private channel 5.
[0083] According to the composition of drawing 8 , since storage equipment 12-1 - 12-n can be directly seen from all the file servers 10-1 - 10-n, replication operation and a load distribution which were stated with the operation gestalt of the above 4th can be easily performed by giving the load status information attaching part 16-1 classified by file in drawing 6 - 16-n to each server 10-1 - 10-n. In addition, the network (interface) in which a multi-host is possible may not be restricted to FC-AL80, and may be a SCSI (Small Computer System Interface) bus.
[0084]
[Effect of the Invention] As explained in full detail above, according to this invention, from a client, he can treat two or more file servers distributed on the network as a single server, and a client is not made conscious of the connection state of the number of a server, or storage equipment.
[0085] Moreover, according to this invention, when a server is extended, volume can also be extended dynamically.
[0086] Furthermore, according to this invention, an autonomous load distribution is realizable among two or more servers.

[Translation done.]

DESCRIPTION OF DRAWINGS

[Brief Description of the Drawings]
[Drawing 1] The block diagram showing the composition of the computer network system which applies the virtual distribution file server system concerning the 1st operation gestalt of this invention.
[Drawing 2] Drawing showing the example of a data structure of the mapping table in drawing 1 .
[Drawing 3] Drawing showing the example of a data structure of the server information attaching part in drawing 1 .
[Drawing 4] The block diagram showing the composition of the computer network system which applies the virtual distribution file server system concerning the 2nd operation gestalt of this invention.
[Drawing 5] The block diagram showing the composition of the computer network system which applies the virtual distribution file server system concerning the 3rd operation gestalt of this invention.
[Drawing 6] The block diagram showing the composition of the computer network system which applies the virtual distribution file server system concerning the 4th operation gestalt of this invention.
[Drawing 7] Drawing showing the example of a data structure of the load status information attaching part classified by file in drawing 6 .
[Drawing 8] The timing chart explaining operation of this operation gestalt.
[Description of Notations]
1, 4, 6, 8 -- Virtual distribution file server system
2 -- Client
3 -- Network
5 -- Private channel
10-1 - 10-n -- File server
11, 41, 61 -- Virtual distributed file system
12-1 - 12-n -- Storage equipment
13-1 - 13-n -- Local file system
14-1 - 14-n -- Mapping table
15-1 - 15-n -- Server information attaching part
16-1 - 6-n -- Load status information attaching part classified by file
80 -- FC-AL (interface in which a multi-host is possible)
110-1 - 110-n, 410-1 - 410-n -- Virtual distribution file module (management module)
111-1 - 111-n -- Virtual distribution file interface
112-1 - 112-n -- Local file interface
113-1 - 113-n -- Communication module
611 -- File
612 -- (file 611) Replica

[Translation done.]

(19)日本国特許庁（ＪＰ）　(12) **公開特許公報（A）**　(11)特許出願公開番号
特開2001－51890
（P2001－51890A）
(43)公開日　平成13年２月23日(2001.2.23)

(51)Int.Cl.'	識別記号	FI	テーマコード'(参考)
G06F 12/00	545	G06F 12/00	545A 5B082
13/00	351	13/00	351E 5B089

審査請求　未請求　請求項の数７　ＯＬ　（全 14 頁）

(21)出願番号　特願平11－226494

(22)出願日　平成11年８月10日(1999.8.10)

(71)出願人　000003078
株式会社東芝
神奈川県川崎市幸区堀川町72番地
(72)発明者　内堀　郁夫
東京都府中市東芝町１番地　株式会社東芝府中工場内
(72)発明者　高桑　正幸
東京都府中市東芝町１番地　株式会社東芝府中工場内
(74)代理人　100058479
弁理士　鈴江　武彦　（外６名）

最終頁に続く

(54)【発明の名称】　仮想分散ファイルサーバシステム

(57)【要約】
【課題】ネットワーク上に分散した複数のファイルサーバの台数やストレージ装置の接続状態をクライアントに意識させないで済むようにする。
【解決手段】ネットワーク３上に分散したサーバ１０-1，１０-2を備え、各サーバには、仮想分散ファイルシステム１１が分散して実装されている。このシステム１１を構成する、サーバ１０-1，１０-2上のモジュール１１０-1，１１０-2は、クライアント２からマルチキャストされたファイル操作要求を受け取ると、仮想分散ファイルシステム１１と全ローカルファイルシステム１３-1，１３-2とのマッピングテーブル１４-1，１４-2または全サーバのサーバ情報を保持するサーバ情報保持部１５-1，１５-2をもとに、自サーバが上記要求を処理可能な最適なサーバであるか否かを判断し、その判断結果に基づいて要求されたファイル操作を対応するサーバのローカルファイルシステムにより行わせる。

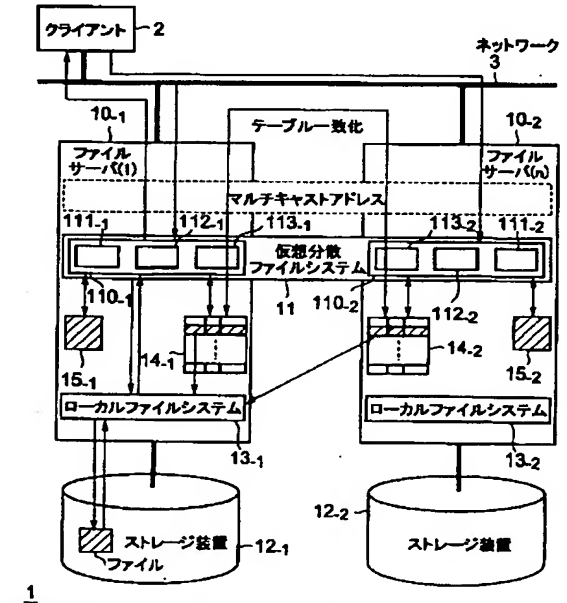

【特許請求の範囲】

【請求項１】　マルチキャスト可能なネットワーク上に分散した複数のファイルサーバを備えた仮想分散ファイルサーバシステムであって、

前記各ファイルサーバに分散して実装され、全ファイルサーバのファイルを統合的に管理する、実際のストレージ構成には非依存の仮想分散ファイルシステムと、

前記各ファイルサーバにそれぞれ独立して実装され、各サーバに固有のストレージ構成を管理するローカルファイルシステムと、

前記各ファイルサーバにそれぞれ設けられ、前記仮想分散ファイルシステムで統合的に管理される各ファイルについて、当該仮想分散ファイルサーバシステムとそのファイルを実際に管理する前記ローカルファイルシステムとの間のマッピングの情報を保持するマッピングテーブルとを具備し、

前記仮想分散ファイルシステムは、前記各ファイルサーバにそれぞれ設けられた管理モジュールから構成され、

前記各管理モジュールは、クライアントからマルチキャストされたファイル操作要求を共通に受け取り、当該要求に応じて自サーバの前記マッピングテーブルを参照することで、自サーバが当該要求を処理可能な最適なサーバであるか否かを判断し、最適なサーバであると判断した場合だけ、要求されたファイル操作を対応するサーバの前記ローカルファイルシステムにより行わせるように構成されていることを特徴とする仮想分散ファイルサーバシステム。

【請求項２】　マルチキャスト可能なネットワーク上に分散した複数のファイルサーバを備えた仮想分散ファイルサーバシステムであって、

前記各ファイルサーバに分散して実装され、全ファイルサーバのファイルを統合的に管理する、実際のストレージ構成には非依存の仮想分散ファイルシステムと、

前記各ファイルサーバにそれぞれ独立して実装され、各サーバに固有のストレージ構成を管理するローカルファイルシステムと、

前記各ファイルサーバにそれぞれ設けられ、前記仮想分散ファイルシステムで統合的に管理される各ファイルについて、当該仮想分散ファイルサーバシステムとそのファイルを実際に管理する前記ローカルファイルシステムとの間のマッピングの情報を保持するマッピングテーブルと、

前記各ファイルサーバにそれぞれ設けられ、全ての前記ファイルサーバについて、そのサーバのストレージ装置の空き容量を示す情報、及びそのサーバの負荷状況を示す情報の少なくとも一方を含むサーバ情報を保持するサーバ情報保持手段とを具備し、

前記仮想分散ファイルシステムは、前記各ファイルサーバにそれぞれ設けられた管理モジュールから構成され、

前記各管理モジュールは、クライアントからマルチキャストされたファイル操作要求を共通に受け取り、当該要求に応じて自サーバの前記マッピングテーブルまたは前記サーバ情報保持手段を参照することで、自サーバが当該要求を処理可能な最適なサーバであるか否かを判断し、最適なサーバであると判断した場合だけ、要求されたファイル操作を対応するサーバの前記ローカルファイルシステムにより行わせるように構成されていることを特徴とする仮想分散ファイルサーバシステム。

【請求項３】　前記管理モジュールは、前記ファイル操作要求がファイル読み出し要求またはファイル書き込み要求の場合には、自サーバの前記マッピングテーブルを参照し、該当するファイルが自サーバの前記ローカルファイルシステムの管理下にあるか否かにより、自サーバが前記要求を処理可能な最適なサーバであるか否かを判断することを特徴とする請求項１または請求項２記載の仮想分散ファイルサーバシステム。

【請求項４】　前記管理モジュールは、前記ファイル操作要求がファイルの新規作成要求の場合には、自サーバの前記サーバ情報保持手段を参照し、全ての前記サーバの各々について、そのサーバのストレージ装置の空き容量、またはそのサーバの負荷状況を比較することで、自サーバが前記要求を処理可能な最適なサーバであるか否かを判断することを特徴とする請求項２記載の仮想分散ファイルサーバシステム。

【請求項５】　前記管理モジュールは、全ての前記ファイルサーバの前記マッピングテーブルの内容を一致化するために、自サーバの前記マッピングテーブルの情報と他のサーバの前記マッピングテーブルの情報とをサーバ間通信により交換することを特徴とする請求項１記載の仮想分散ファイルサーバシステム。

【請求項６】　前記管理モジュールは、全ての前記ファイルサーバの前記マッピングテーブルの内容を一致化するために、自サーバの前記マッピングテーブルの情報と他のサーバの前記マッピングテーブルの情報とをサーバ間通信により交換する一方、全ての前記ファイルサーバの前記サーバ情報保持手段の内容を一致化するために、自サーバの前記サーバ情報保持手段の情報と他のサーバの前記サーバ情報保持手段の情報とをサーバ間通信により交換することを特徴とする請求項２記載の仮想分散ファイルサーバシステム。

【請求項７】　前記各ファイルサーバにそれぞれ設けられ、そのサーバの管理下にある各ファイル別の負荷状況を示す情報を保持するファイル別負荷状況情報保持手段を更に具備し、

前記管理モジュールは、自サーバの前記ファイル別負荷状況情報保持手段に保持されている情報から第１の閾値を超えた負荷のファイルを検出して、他の任意のファイルサーバに対してサーバ間通信により当該ファイルのレプリケーションを行い、クライアントからマルチキャストされた当該ファイルの読み出し要求があった場合、当

該要求に対する処理をレプリケーション側に任せるようにしたことを特徴とする請求項１または請求項２記載の仮想分散ファイルサーバシステム。

【発明の詳細な説明】

【０００１】

【発明の属する技術分野】本発明は、コンピュータ・ネットワークシステムにおけるファイルサーバシステムに係り、特にネットワーク上に接続された複数のファイルサーバを協調動作させて、クライアントからは単一のサーバとして機能させる仮想分散ファイルサーバシステムに関する。

【０００２】

【従来の技術】今日のコンピュータ・ネットワークシステムにおいては、ネットワークに接続された異なるコンピュータ間でファイルを共有することが一般的に行われている。こうした環境下では、特定のコンピュータに大規模なストレージを接続して、ファイルサーバとして運用したり、最近ではＮＡＳ（Network Attached Storage）と呼ばれる、ファイルサーバ専用機を接続する等のシステム構成をとることが多い。

【０００３】ファイルサーバを使用する環境（ファイルサーバシステム）では、サーバのストレージ容量が不足した場合には、サーバ側に物理的・性能的に拡張性があれば、新たにディスク装置等（のストレージ装置）を増設することで対処できる。このときクライアントからは、新たなボリュームをマウントして使用するといった形態になる。また、サーバの拡張性が限界に達していれば、サーバ自体を増設することになる。このときクライアントからは、増設したサーバを意識した上で新たなボリュームをマウントして使用するといった形態になる。

【０００４】

【発明が解決しようとする課題】上記したコンピュータ・ネットワークシステムにおいてファイルサーバを利用してファイル共有を行う場合、クライアント側からは、ファイルサーバ側のボリューム構成がそのまま見えてしまうのが一般的である。例えばサーバ側でディスク装置を増設した場合には、クライアント側は新たなボリュームを認識した上で、マウントしなければならない。或いはサーバ自体を増設した場合には、増設したサーバの運用ポリシーを決定、もしくはシステム設定・管理等の煩雑な作業が発生する上、クライアント側でも、新たなサーバを認識した上で、新たなボリュームをマウントしなければならない。

【０００５】このように従来のファイルサーバを用いたファイル共有システム（ファイルサーバシステム）では、ディスク装置（ストレージ装置）の増設、或いはサーバの増設が必要な場合、サーバ側、クライアント側のいずれにも、新たな設定・管理のために多大なコストが発生するという問題があった。更に、ストレージの利用形態よっては、特定のファイルシステムをそのまま容量だけ拡張したい場合もあり、単にストレージ装置やサーバを増設するだけでは解決しないケースもあった。

【０００６】本発明は上記事情を考慮してなされたものでその目的は、ネットワーク上に分散した複数のファイルサーバを、クライアントからは単一のサーバとして扱うことができ、サーバ台数やストレージ装置の接続状態をクライアントに意識させない仮想分散ファイルサーバシステムを提供することにある。

【０００７】

【課題を解決するための手段】本発明は、マルチキャスト可能なネットワークに接続された複数のファイルサーバに分散して実装され、全ファイルサーバのファイルを統合的に管理する、実際のストレージ構成には非依存の仮想分散ファイルシステムと、各ファイルサーバにそれぞれ独立して実装され、各サーバに固有のストレージ構成を管理するローカルファイルシステムと、前記各ファイルサーバにそれぞれ設けられ、上記各ファイルについて、仮想分散ファイルサーバシステムとそのファイルを実際に管理するローカルファイルシステムとの間のマッピングの情報（例えば、仮想分散ファイルサーバシステムで管理され、クライアントから見える仮想的なパスと、ローカルファイルシステムで管理され、クライアントから見えない物理的な所在とを対応付けた情報）を保持するマッピングテーブルとを備えると共に、上記仮想分散ファイルシステムを、各ファイルサーバにそれぞれ設けられた管理モジュールであって、クライアントからマルチキャストされたファイル操作要求を共通に受け取り、当該要求に応じて自サーバのマッピングテーブルを参照することで、自サーバが当該要求を処理可能な最適なサーバであるか否かを判断し、最適なサーバであると判断した場合だけ、要求されたファイル操作を対応するサーバのローカルファイルシステムにより行わせる管理モジュールにより構成することを特徴とする。

【０００８】ここで、各ファイルサーバ上に、全ファイルサーバについて、そのサーバのストレージ装置の空き容量を示す情報、及びそのサーバの負荷状況を示す情報の少なくとも一方を含むサーバ情報を保持するサーバ情報保持手段を更に設け、上記各管理モジュールでは、クライアントからマルチキャストされたファイル操作要求を受け取った場合に、当該要求に応じて自サーバのマッピングテーブルまたはサーバ情報保持手段を参照することで、自サーバが当該要求を処理可能な最適なサーバであるか否かを判断する構成としてもよい。

【０００９】このような構成においては、クライアントから特定のファイルサーバを意識することなくマルチキャストされたファイル操作要求は、仮想分散ファイルサーバシステムを構成する各ファイルサーバ上の管理モジュールで共通に受け取られ、その要求に応じて対応するサーバ（自サーバ）のマッピングテーブルまたはサーバ情報保持手段が参照される。そして、この参照の結果、

自サーバが上記要求を処理可能な最適なサーバであるか否かが判断され、最適なサーバであると判断した唯一のサーバ（上の管理モジュール）だけが、要求されたファイル操作を自サーバのローカルファイルシステムにより行わせる。

【００１０】このように、要求元のクライアントからは、ネットワーク上に分散した複数のファイルサーバを単一のサーバとして扱うことができ、サーバ台数やストレージ装置の接続状態を意識する必要がない。

【００１１】ここで、上記管理モジュールで、自サーバが最適なサーバであるか否かを判断するためのアルゴリズムとして、以下の第１乃至第４のアルゴリズム（判断手法）のいずれかを適用するとよい。

【００１２】第１のアルゴリズムは、ファイル操作要求がファイル読み出し要求またはファイル書き込み要求の場合に適用されるもので、自サーバのマッピングテーブルの情報に基づいて、該当するファイルが自サーバのローカルファイルシステムの管理下にあるか否かにより判断する手法である。

【００１３】第２のアルゴリズムは、ファイル操作要求がファイルの新規作成要求の場合に適用されるもので、自サーバのサーバ情報保持手段の情報に基づいて、全てのサーバの各々について、そのサーバのストレージ装置の空き容量（空き記憶容量）、またはそのサーバの負荷状況を比較することで判断する（例えば、自サーバの空き容量が最も大きい場合、或いは自サーバの負荷が最も低い場合に上記最適サーバと判断する）手法である。

【００１４】第３のアルゴリズムも、ファイル操作要求がファイルの新規作成要求の場合に適用されるもので、自サーバのマッピングテーブルの情報に基づいて、全てのサーバの各々について対応するストレージ装置上に確保可能な連続領域を求め、その連続領域のサイズを比較することで判断する（例えば、自サーバのストレージ装置上に確保可能な連続領域のサイズが最も大きい場合に上記最適サーバと判断する）手法である。

【００１５】第４のアルゴリズムも、ファイル操作要求がファイルの新規作成要求の場合に適用されるもので、全てのサーバの各々について、そのサーバのストレージ装置の空き容量、そのサーバの負荷、及び当該ストレージ装置上に確保可能な連続領域の少なくとも２つを求め、その求めた少なくとも２つの情報を複合条件として比較することで判断する手法である。

【００１６】以上の第１乃至第４のアルゴリズムのいずれか１つを適用することで、クライアントから特定のファイルサーバを意識することなくマルチキャストされたファイル操作要求を各サーバが共通に受け取っても、その要求されたファイル操作を行うのに最適なサーバであるか否かを、その都度相互に通信を行うことなく、そのサーバ自身で自律的に判断することができる。

【００１７】ここで、上記各管理モジュールに、全てのファイルサーバのマッピングテーブルの内容を一致化するために、自サーバのマッピングテーブルの情報と他サーバのマッピングテーブルの情報とをサーバ間通信により交換する機能（通信モジュール）を持たせるとよい。また、マッピングテーブルに加えてサーバ情報保持手段を各サーバ上に備えた構成では、各管理モジュール（内の通信モジュール）に、全てのファイルサーバのサーバ情報保持手段の内容を一致化するために、自サーバのサーバ情報保持手段の情報と他のサーバのサーバ情報保持手段の情報とをサーバ間通信により交換する機能を更に持たせるとよい。

【００１８】また、マッピングテーブルの一致化のためには、自サーバのローカルファイルシステムで実際に管理されるファイル構成が変更された場合に、その変更された情報（マッピング情報）をサーバ間通信により他の全サーバに送信するのが効率的である。同様に、サーバ情報保持手段の内容の一致化のためには、自サーバのサーバ情報を定期的に更新し、その都度、その更新されたサーバ情報をサーバ間通信により他の全サーバに送信するのが効率的である。

【００１９】また本発明は、上記仮想分散ファイルサーバシステムにサーバが動的に増設された場合に、そのサーバの管理モジュールで以下の第１乃至第４の処理を行うようにしたことをも特徴とする。まず、第１の処理では、サーバ間通信により他の全てのサーバに対してマッピングテーブル及びサーバ情報保持手段の更新を禁止するロック設定を行い、次の第２の処理では、サーバ間通信により他の任意のサーバからマッピングテーブルサーバ情報保持手段の内容を自サーバにコピーし、次の第３の処理では、自サーバのサーバ情報保持手段に自サーバのサーバ情報を追加し、次の第４の処理では、サーバ間通信により自サーバのーバ情報を他の全てのサーバのサーバ情報保持手段に反映させて全サーバのサーバ情報保持手段の一致化を図り、しかる後に上記ロック設定を解除する。

【００２０】このようなサーバ増設時の一連の動作により、動的にサーバ台数を拡張できる。しかもクライアントは、サーバ台数の拡張を意識することなく、増設されたサーバを利用することができる。

【００２１】また本発明は、各ファイルサーバに、そのサーバの管理下にある各ファイル別の負荷状況を示す情報を保持するファイル別負荷状況情報保持手段を付加し、各サーバの管理モジュールにおいて、自サーバのファイル別負荷状況情報保持手段に保持されている情報から第１の閾値を超えた負荷のファイルを検出して、他の任意のファイルサーバに対してサーバ間通信により当該ファイルのレプリケーションを行い、クライアントからマルチキャストされた当該ファイルの読み出し要求があった場合、当該要求に対する処理をレプリケーション側に任せるようにしたことをも特徴とする。

【００２２】このような構成においては、自律的な負荷分散が可能となる。ここで、上記検出したファイルがレプリケーションされたファイルである場合にも、他の任意のファイルサーバに対してサーバ間通信により当該ファイルのレプリケーションを行い、クライアントからマルチキャストされた当該ファイルの読み出し要求があった場合に、当該要求に対する処理を新たなレプリケーション側に任せることにより、自律的な負荷分散がより広範囲に効果的に行える。また、他サーバへのレプリケーションの対象となったファイルの負荷が前記第１の閾値より低い第２の閾値以下となった場合に、そのレプリケーションを行ったサーバ上の管理モジュールから当該他サーバに対してサーバ間通信により対応するファイルの消去を要求し、クライアントからマルチキャストされた当該ファイルの読み出し要求があった場合、当該要求に対する処理を自身が行うことにより、動的な負荷分散が可能となる。

【００２３】さて、上記一致化のためのサーバ間通信（マッピング情報またはサーバ情報の通信）、更には上記レプリケーションのためのサーバ間通信には、上記ネットワークを用いることが可能である。しかし、各ファイルサーバを相互接続する専用の通信路（プライベート通信路）を上記ネットワークから独立に設け、当該通信路を用いてサーバ間通信を行う構成とするとよい。この場合、サーバ間通信のためにネットワークのスループットが悪化するのを防止できる。

【００２４】また本発明は、各ファイルサーバ及び当該サーバのストレージ装置を相互接続するマルチホストが可能なインタフェースを更に備えると共に、上記各管理モジュールによる上記サーバ間通信を当該インタフェースを介して行うようにしたことをも特徴とする。

【００２５】このような構成においては、上記各ストレージ装置を上記インタフェースによって各サーバ間で共有し、上記一致化のためのサーバ間通信、更には動的なファイルのレプリケーションのためのサーバ間通信が上記インタフェースを通して行われるため、自律的な負荷分散が効果的に実現される。

【００２６】なお、本発明は方法に係る発明としても成立する。

【００２７】

【発明の実施の形態】以下、本発明の実施の形態につき図面を参照して説明する。

【００２８】［第１の実施形態］図１は本発明の第１の実施形態に係る仮想分散ファイルサーバシステムを適用するコンピュータ・ネットワークシステムの構成を示すブロック図である。

【００２９】同図において、１は仮想分散ファイルサーバシステム、２は同ファイルサーバシステム１にファイルサービスを要求するクライアント（クライアントコンピュータ）である。仮想分散ファイルサーバシステム１は、ネットワーク３上に分散配置された複数、例えば２台のファイルサーバ（サーバコンピュータ）１０-1，１０-2を用いて実現される。なお、図ではクライアント２は便宜的に１台だけが示されているが、複数存在するのが一般的である。

【００３０】１１は仮想分散ファイルサーバシステム１の中心をなす仮想分散ファイルシステムであり、各ファイルサーバ１０-1，１０-2に分散して実装されている。この仮想分散ファイルシステム１１は、全ファイルサーバ１０-1，１０-2のファイルを統合的に管理し、ファイルサーバ１０-1，１０-2それぞれの実際のボリューム構成（ストレージ構成）には依存しない、仮想的なファイルシステムをクライアント２に対して提供するものである。

【００３１】仮想分散ファイルシステム１１は、各ファイルサーバ１０-1，１０-2に分散して実装された仮想分散ファイルモジュール１１０-1，１１０-2を有している。仮想分散ファイルモジュール１１０-1，１１０-2は、ファイルサーバ１０-1，１０-2上でクライアント２からの要求を分散して処理しつつ、クライアント２に対しては仮想的に１つのファイルシステムとして見せるための管理モジュールである。仮想分散ファイルモジュール１１０-1，１１０-2は、当該モジュール１１０-1，１１０-2の中心をなし、クライアント２からの要求を処理する仮想分散ファイルインタフェース１１１-1，１１１-2と、後述するローカルファイルシステム１３-1，１３-2とのインタフェース（ローカルファイルインタフェース）１１２-1，１１２-2と、当該モジュール１１０-1，１１０-2間での通信（後述するマッピングテーブル１４-1，１４-2の情報、及びサーバ情報の一致化のための通信に代表されるサーバ間通信）を行う通信モジュール１１３-1，１１３-2とを持つ。

【００３２】ファイルサーバ１０-1，１０-2はネットワーク３を介してクライアント２と接続されている。ファイルサーバ１０-1，１０-2は、仮想分散ファイルシステム１１の他に、それぞれ当該サーバ１０-1，１０-2に接続されたディスク装置などのストレージ装置１２-1，１２-2（実際のストレージ構成）を管理するローカルなファイルシステム（ローカルファイルシステム）１３-1，１３-2を実装している。

【００３３】ファイルサーバ１０-1，１０-2には、仮想分散ファイルシステム１１とローカルファイルシステム１３-1，１３-2とを対応付ける同一内容のマッピングテーブル１４-1，１４-2が設けられている。このテーブル１４-i（ｉ＝１，２）のデータ構造を図２に示す。

【００３４】テーブル１４-iの各エントリは、仮想分散ファイルシステム１が管理するファイルのファイル名の登録フィールド（ファイル名フィールド）１４１と、当該ファイルの仮想分散ファイルシステム１上の論理的な所在を表す（クライアント２から見える）パス（仮想パ

ス）の登録フィールド（仮想パスフィールド）１４２、当該ファイルのストレージ上の物理的な所在位置を表す（クライアント２から見えない）所在位置情報の登録フィールド（所在位置情報フィールド）１４３、当該ファイルへのアクセス権（許可／禁止）を管理するためのパーミッション情報の登録フィールド（パーミッション情報フィールド）１４４、及びその他の各種属性の登録フィールド１４５を有している。

【００３５】仮想分散ファイルシステム１１（上の仮想分散ファイルモジュール１１０-i）は、このようなデータ構造のマッピングテーブル１４-iを参照することにより、例えばあるファイルがファイルサーバ１０-1，１０-2のいずれにあるか等の所在情報を得ることができる他、パーミッション等、必要に応じてファイルの属性を得ることができる。

【００３６】ファイルサーバ１０-1，１０-2には更に、同一内容のサーバ情報保持部１５-1，１５-2が設けられている。サーバ情報保持部１５-i（ｉ＝１，２）は、図３に示すように、仮想分散ファイルサーバシステム１を構成する全てのファイルサーバ１０-1，１０-2の（ストレージ装置１２-1，１２-2の）空き記憶容量を示す情報（リソース情報）、及び負荷状況を示す情報を含むサーバ情報を保持するのに用いられる。

【００３７】次に図１の構成の動作を説明する。本実施形態では、クライアント２からは、各ファイルサーバ１０-1，１０-2のローカルファイルシステム１３-1，１３-2ではなくて、仮想分散ファイルシステム１１がマウントされているように見えている。そこでクライアント２は、何らかのファイル操作要求が発生した場合、仮想分散ファイルシステム１１が実装されている全ファイルサーバ１０-1，１０-2に対して同一の要求を発行する。この場合、例えばＩＰ（Internet Protocol）マルチキャストを使用する等の手法によれば、クライアント２側はファイルサーバの台数を意識することなく要求の発行が可能である。

【００３８】ファイルサーバ１０-1，１０-2は、クライアント２からの要求を受け取ると、当該要求を仮想分散ファイルシステム１１内の自サーバに対応した仮想分散ファイルモジュール１１０-1，１１０-2に渡す。すると、モジュール１１０-1，１１０-2（内の仮想分散ファイルインタフェース１１１-1，１１１-2）は、その要求がファイルの読み出し要求もしくは書き込み（更新）要求であるか、または新規ファイルの作成要求もしくはディレクトリの作成要求であるか、その要求種別を判別する。

【００３９】ここで、クライアント２からのファイル操作要求がファイルの読み出し要求もしくは書き込み要求であるものとする。この要求には、要求の対象となるファイルのファイル名と、当該ファイルの仮想分散ファイルシステム１１上のパス（仮想パス）が付されている。

【００４０】仮想分散ファイルモジュール１１０-1，１１０-2（内の仮想分散ファイルインタフェース１１１-1，１１１-2）は、クライアント２からのファイル操作要求がファイルの読み出し要求もしくは書き込み要求の場合、要求されたファイルのファイル名及び仮想パスにより自サーバ内のマッピングテーブル１４-1，１４-2を参照し、当該ファイル名及び仮想パスを持つテーブル１４-1，１４-2内エントリ中の所在位置情報フィールド１４３の登録情報から、操作要求のあったファイルが自サーバ内（自サーバに接続されたストレージ装置１２-1，１２-2）に保持されているか否かを調べる。

【００４１】もし、要求されたファイルが自サーバ内に保持されている場合には、仮想分散ファイルモジュール１１０-1，１１０-2（内の仮想分散ファイルインタフェース１１１-1，１１１-2）は、ローカルファイルインタフェース１１２-1，１１２-2により自サーバ内のローカルファイルシステム１３-1，１３-2を介して実際のファイルにアクセスし、クライアント２に応答を返す。一方、操作要求のあったファイルが自サーバ内になかった場合には、他のサーバが応答するものと見なして応答しない。

【００４２】これに対し、クライアント２からの要求が新規ファイルの作成、或いはディレクトリの作成であった場合には、仮想分散ファイルモジュール１１０-1，１１０-2は、（マッピングテーブル１４-1，１４-2ではなくて）サーバ情報保持部１５-1，１５-2を参照する。そして、サーバ情報保持部１５-1，１５-2に保持されている全サーバのサーバ情報をもとに、所定のアルゴリズムに従い、いずれか１つのサーバ１０-i（ｉは１または２）上の仮想分散ファイルモジュール１１０-iだけが、仮想分散ファイルインタフェース１１１-iによりクライアント２からの要求を受け付ける。具体的には、サーバ１０-i上の仮想分散ファイルモジュール１１０-iは、全サーバのサーバ情報の示す空き記憶容量を比較し、自サーバ１０-i（のストレージ装置１２-i）の空き記憶容量が最も大きいと判定できる場合に、クライアント２からの要求を受け付けるものとする。この場合、必ずしもサーバ情報中に負荷状況の情報を持たせる必要はない。

【００４３】なお、全サーバのサーバ情報の示す負荷を比較し、自サーバの負荷が最も低い場合にクライアント２からの要求を受け付けるようにしてもよい。この場合、必ずしもサーバ情報中に対応するサーバの空き記憶容量の情報を持たせる必要はない。

【００４４】この他に、マッピングテーブル１４-iの各ファイル毎のマッピング情報から（つまり各ストレージ装置１２-1，１２-2の領域の使用状況から）、各ストレージ装置１２-1，１２-2上に確保可能な連続領域を求め、必要なサイズ以上の連続領域が確保でき、且つそのサイズが最も大きいストレージ装置が自サーバのストレージ装置１２-iの場合に、クライアント２からの要求を

受け付けるようにしてもよい。この場合、サーバ情報保持部１５-1，１５-2は必ずしも必要でない。

【００４５】更に、空き記憶容量と負荷状況と確保できる連続領域のサイズの少なくとも２つを条件（複合条件）として評価値を求め、自サーバが要求を受け付ける最適なサーバであるか否かを判断ようにしてもよい。

【００４６】さて、ファイルサーバ１０-i上の仮想分散ファイルモジュール１１０-iでは、仮想分散ファイルインタフェース１１１-iによりクライアント２からの要求を受け付けると、要求された新規ファイルの作成、或いはディレクトリの作成を、ローカルファイルインタフェース１１２-iを介してローカルファイルシステム１３-iにより行い、マッピングテーブル１４-1，１４-2に該当するエントリ情報を登録する。

【００４７】新規ファイルの作成、或いはディレクトリの作成が完了した後は、ファイルサーバ１０-i上の仮想分散ファイルモジュール１１０-iでは、自サーバ上のマッピングテーブル１４-iに登録した新たなエントリ情報を通信モジュール１１３-iによりネットワーク３を介して他の全てのサーバ１０-j（ｊは1または2、但しｊ≠ｉ）上の仮想分散ファイルモジュール１１０-ｊに送る。仮想分散ファイルモジュール１１０-ｊ（内の仮想分散ファイルインタフェース１１１-j）は、仮想分散ファイルモジュール１１０-iから送られたマッピングテーブル１４-iのエントリ情報を通信モジュール１１３-jを介して受け取る。そしてモジュール１１０-ｊ（内のインタフェース１１１-j）は、受け取った他サーバ１０-iのマッピングテーブル１４-iのエントリ情報を自サーバ内のマッピングテーブル１４-jに登録する。このように、ファイルサーバ１０-1，１１０-2上の仮想分散ファイルモジュール１１０-1，１１０-2が相互にマッピングテーブル１４-1，１４-2の新規登録されたエントリ情報（更には更新されたエントリ情報）を交換し合うことで、当該マッピングテーブル１４-1，１４-2の内容の一致化を図ることができる。

【００４８】また、ファイルサーバ１０-1，１０-2上の仮想分散ファイルモジュール１１０-1，１１０-2は、自サーバ上のサーバ情報保持部１５-1，１５-2に保持されている各サーバのサーバ情報のうち、自サーバのサーバ情報（空き記憶容量、及び負荷状況）を定期的に更新すると共に、その更新したサーバ情報を（通信モジュール１１３-1，１１３-2により）ネットワーク３を介して他の全てのサーバ（上の仮想分散ファイルモジュール１１０-2，１１０-1）に定期的に送ることで、各ファイルサーバ１０-1，１０-2のサーバ情報保持部１５-1，１５-2の内容の一致化を図る。つまり仮想分散ファイルモジュール１１０-1，１１０-2は定期的にサーバ情報を交換し合うことで一致化を図る。

【００４９】以上の動作によって、ファイルサーバ１０-1，１０-2を自律的に分散・協調動作させることができ、クライアント２には実際にはファイルサーバが２台（複数台）あることを意識させずに、仮想的なファイルサーバを提供することができる。

【００５０】なお、図１のシステムの例ではサーバが２台である場合について説明したが、サーバが３台以上であっても同様の仕組みによって、仮想的なファイルサーバを提供することができる。

【００５１】［第２の実施形態］図４は本発明の第２の実施形態に係る仮想分散ファイルサーバシステムを適用するコンピュータ・ネットワークシステムの構成を示すブロック図であり、図１と同一部分には同一符号を付してある。

【００５２】図４において、仮想分散ファイルサーバシステム４の中心をなす仮想分散ファイルシステム４１は、ｎ台のファイルサーバ１０-1～１０-nに分散して実装されている。この仮想分散ファイルシステム４１は、図１中の仮想分散ファイルシステム１１と同様に、全ファイルサーバ１０-1～１０-nのファイルを統合的に管理し、各ファイルサーバ１０-1～１０-nそれぞれの実際のボリューム構成には依存しない、仮想的なファイルシステムをクライアント２に対して提供している。仮想分散ファイルシステム４１は、各ファイルサーバ１０-1～１０-n上でクライアント２からの要求を処理する仮想分散ファイルモジュール４１０-1～４１０-nを有している。モジュール４１０-1～４１０-nは、図１中のモジュール１１０-1，１１０-2と同様の構成である、仮想分散ファイルインタフェース４１１-1～４１１-nと、ローカルファイルインタフェース４１２-1～４１２-nと、通信モジュール４１３-1～４１３-nとを持つ。但し、本実施形態における通信モジュール４１３-1～４１３-nは、図１中の通信モジュール１１３-1，１１３-2と異なり、後述するプライベート通信路５を介して通信を行うように構成されている。

【００５３】ファイルサーバ１０-1～１０-nはネットワーク３を介してクライアント２と接続されている。ファイルサーバ１０-1～１０-nは、仮想分散ファイルシステム１１の他に、それぞれ当該サーバ１０-1～１０-nに接続されたストレージ装置１２-1～１２-2を管理するローカルなファイルシステム（ローカルファイルシステム）１３-1～１３-2を実装している。ファイルサーバ１０-1～１０-nには、マッピングテーブル１４-1～１４-nと、サーバ情報保持部１５-1～１５-2とが設けられている。

【００５４】図４の構成の仮想分散ファイルサーバシステム４の特徴は、図１の構成の仮想分散ファイルサーバシステム１と異なって、システムを構成するファイルサーバの台数がｎ台である点と、そのｎ台のファイルサーバ１０-1～１０-nがネットワーク３とは別のプライベートな通信路５によっても相互接続されている点である。このプライベート通信路５は、例えばイーサネット、或いはファイバチャネル（Fibre Channnel）等であるが、

物理層に関しては特定しない。またトポロジに関しても、図４の例ではバス型を想定しているが、ループやスイッチであってもよい。

【００５５】図４の構成において、ファイルサーバ１０-1～１０-nが（仮想分散ファイルシステム４１内の仮想分散ファイルモジュール４１０-1～４１０-nにより）分散・協調動作を行うためには、前記第１の実施形態での動作説明から類推されるように、マッピングテーブル１４-1～１４-n、及びサーバ情報保持部１５-1～１５-nの内容を、各サーバ１０-1～１０-n間で常に一致化させておく必要がある。しかし、サーバ１０-1～１０-n間の情報一致化を、前記第１の実施形態と同様にネットワーク３を介して行うのでは、仮想分散ファイルサーバシステム４を構成するファイルサーバの台数が増加した場合には、その情報一致化の（ためのサーバ間通信の）トラフィックが増加し、ネットワーク３上のスループットを悪化させることになる。

【００５６】そこで本実施形態（第２の実施形態）では、図４の構成のように、各ファイルサーバ１０-1～１０-n間にサーバ間の情報交換専用のプライベート通信路５を設け、仮想分散ファイルシステム４１内の仮想分散ファイルモジュール４１０-1～４１０-nで通信モジュール４１３-1～４１３-nにより行われるサーバ間通信に、即ちマッピングテーブル１４-1～１４-n、及びサーバ情報保持部１５-1～１５-nの内容を一致化するためのサーバ間通信に、この通信路５を使用するようにしている。

【００５７】このように本実施形態では、マッピングテーブル１４-1～１４-n、及びサーバ情報保持部１５-1～１５-nの内容の一致化のためのサーバ間通信に、ネットワーク３でなくてプライベート通信路５を用いることにより、ネットワーク３の負荷の軽減を図ることができる。

【００５８】［第３の実施形態］以上に述べた第１、第２の実施形態では、複数のファイルサーバを分散・協調動作させる仮想分散ファイルサーバシステムの構成例を示した。この第１、第２の実施形態で参照した図１、図４の構成は、特定のサーバ台数における静的な例である。しかし、サーバ台数については、変更可能な構成とすることが好ましい。

【００５９】そこで、仮想分散ファイルサーバシステムを構成するサーバ台数を動的に拡張可能とした本発明の第３の実施形態について図面を参照して説明する。図５は本発明の第３の実施形態に係る仮想分散ファイルサーバシステムを適用するコンピュータ・ネットワークシステムの構成を示すブロック図であり、図４と同一部分には同一符号を付してある。

【００６０】まず、図４に示した仮想分散ファイルサーバシステム４、即ちｎ台のファイルサーバ１０-1～１０-nで構成される仮想分散ファイルサーバシステム４に、図５（ａ）に示すように、新たなファイルサーバ１０-(n+1)を追加するものとする。

【００６１】この場合、追加されたファイルサーバ１０-(n+1)にも分散されている仮想分散ファイルシステム４１上の仮想分散ファイルモジュール４１０-(n+1)は、既に仮想分散ファイルサーバシステム４を構成しているファイルサーバ１０-1～１０-nに対し、図５（ａ）において符号Ａ１で示すように、（例えば図示せぬプライベート通信路を介しての）サーバ間通信により、マッピングテーブル１４-1～１４-nのエントリ情報及びサーバ情報保持部１５-1～１５-nのサーバ情報（各サーバのリソース情報及び負荷状況を含む）の更新をロックする。

【００６２】その上で、追加されたサーバ１０-(n+1)上のモジュール４１０-(n+1)は、他のファイルサーバ１０-1～１０-nのうちのいずれかのサーバ、例えばファイルサーバ１０-1から、図５（ｂ）において符号Ａ２で示すように、マッピングテーブル１４-1及びサーバ情報保持部１５-1の全情報を、サーバ間通信により自サーバ内のマッピングテーブル１４-(n+1)及びサーバ情報保持部１５-(n+1)にコピーする。

【００６３】次に、追加されたファイルサーバ１０-(n+1)上のモジュール４１０-(n+1)は、コピー後のサーバ情報保持部１５-(n+1)に対し、図５（ｃ）において符号Ａ３で示すように、自サーバのリソース及び負荷状況を示すサーバ情報を追加する。

【００６４】しかる後にファイルサーバ１０-(n+1)上のモジュール４１０-(n+1)は、図５（ｄ）において符号Ａ４で示すように、サーバ間通信により他の全ファイルサーバ１０-1～１０-nに対してサーバ情報の一致化要求を発行し、その後にロックを解除する。

【００６５】以上の一連の動作により、既に構築されている仮想分散ファイルサーバシステム４に対して、動的に薪たなサーバ（ファイルサーバ１０-(n+1)）を追加することができる。この場合、例えば現在の仮想分散ファイルサーバシステム４のボリューム構成に対し、新規リソースをどのように振り分けるか、といった情報を付加すれば、必要に応じてボリュームを選択的に拡張することも可能である。

【００６６】［第４の実施形態］図６は本発明の第４の実施形態に係る仮想分散ファイルサーバシステムを適用するコンピュータ・ネットワークシステムの構成を示すブロック図であり、図４と同一部分には同一符号を付してある。

【００６７】図６において、６は図４中の仮想分散ファイルサーバシステム４に相当する仮想分散ファイルサーバシステムである。この仮想分散ファイルサーバシステム６の特徴は、当該システム６を構成するファイルサーバ１０-1～１０-n内に、自サーバ（のストレージ装置１２-1～１２-n）に保持されている各ファイルについての負荷状況の情報（ファイル別負荷状況情報）を保持するファイル別負荷状況情報保持部１６-1～１６-nを備えて

いる点にある。これに伴い、仮想分散ファイルサーバシステム６の中心をなす仮想分散ファイルシステム６１の持つ機能も図４中の仮想分散ファイルシステム４１とは一部異なる。但し、仮想分散ファイルシステム６１内の各ファイルサーバ１０-1～１０-n毎の仮想分散ファイルモジュールには便宜的に図４と同一符号（４１０-1～４１０-n）を用いている。なお、図６では、モジュール４１０-1～４１０-n内の構成要素（仮想分散ファイルインタフェース、ローカルファイルインタフェース、通信モジュール）、及びファイルサーバ１０-1～１０-n上のマッピングテーブル、サーバ情報保持部は省略されている。

【００６８】ファイル別負荷状況情報保持部１６-i（i＝1～n）は、図７（a）に示すデータ構造を持ち、自サーバ内のファイル毎の負荷状況を示す情報と、そのファイルの属性を示す情報（ファイル属性）と、レプリケーションフラグとを含むファイル別負荷状況情報を保持する。ファイル属性は、対応するファイルがオリジナルであるかレプリカ（複製）であるかを示す。また、レプリケーションフラグは、対応するフラグがオリジナルの場合、そのレプリカを他サーバ側に生成済みであるか否か、つまりレプリケーション済みであるか否かを示す。

【００６９】図６には、ファイルサーバ１０-nが持つストレージ装置１２-n内に、ファイルサーバ１０-1が持つストレージ装置１２-1内の任意のファイル６１１のレプリカ６１２がレプリケーションＢ１により保持されている様子が示されている。

【００７０】次に、図６の構成の動作を説明する。仮想分散ファイルシステム６１上の各仮想分散ファイルモジュール４１０-1～４１０-nは、ファイル別負荷状況情報保持部１６-1～１６-nを例えば定期的に参照する。そしてモジュール４１０-1～４１０-nは、保持部１６-1～１６-nに保持されているファイル別の負荷状況情報から、自サーバ（のストレージ装置１２-1～１２-n）に保持されているファイルの中に、第１の閾値を超えた負荷のファイルが存在することを検出した場合、他サーバの１つに対して対応するファイルのレプリカを非同期に生成するレプリケーション動作を、例えばプライベート通信路５を介してのサーバ間通信により行う。ここでファイルの負荷状況は、当該ファイルへの要求の待ち行列（キュー）にある要求数、或いは当該ファイルの待ち状態にある要求の示すサイズの総和であり、要求を受け付ける毎と要求を処理し終える毎に更新される。また、レプリケーションの対象サーバには、図示せぬサーバ情報保持部に保持されているサーバ情報に基づいて、例えば負荷が最も低いサーバを選択すればよい。

【００７１】仮想分散ファイルモジュール４１０-1～４１０-nはレプリケーション動作を行うと、自サーバのファイル別負荷状況情報保持部１６-1～１６-nに保持されている対応するファイルの負荷状況情報中のレプリケーションフラグをレプリケーション済みの通知状態にセットする。またレプリケーション動作の対象となったサーバの仮想分散ファイルモジュールは、自サーバのファイル別負荷状況情報保持部内に対応するレプリカの負荷状況情報を追加する。

【００７２】ここでは、図６に示すように、ファイルサーバ１０-1の保持するファイル６１１のレプリケーションＢ１がプライベート通信路５を介してファイルサーバ１０-nに対して行われて、そのレプリカ６１２が当該ファイルサーバ１０-nのストレージ装置１２-nに保持されたものとする。この場合、ファイルサーバ１０-1のファイル別負荷状況情報保持部１６-1に保持されているファイル６１１の負荷状況情報中のレプリケーションフラグがレプリケーション済みを示す状態にセットされる。また、ファイルサーバ１０-nのファイル別負荷状況情報保持部１６-nには、ファイル６１１のレプリカ６１２についての新たな負荷状況情報が追加される。この負荷状況情報中のファイル属性は、対応するファイルが（ファイル６１１の）レプリカ（６１２）であることを示す。

【００７３】以後、クライアント２からファイル６１１の新たな読み出し要求があった場合、当該ファイル６１１を保持するファイルサーバ１０-1（の仮想分散ファイルモジュール４１０-1）は、当該ファイル６１１の負荷が第２の閾値（但し、第２の閾値<第１の閾値）を超えているか否かを調べ、超えているならば、クライアント２からの要求に応答しない。この場合、クライアント２からの要求に対しては、レプリケーションを受けたファイルサーバ１０-nが応答する。ここでファイルサーバ１０-nは、ファイルサーバ１０-1が応答するか否かを考慮する必要はなく、要求されたファイル６１１のレプリカ６１２を有する限り、クライアント２に応答すればよい。

【００７４】このように、クライアント２からのファイル６１１に対する新たな読み出し要求を、そのレプリカ６１２を用いてファイルサーバ１０-nが処理することで、そのファイル６１１を保持するファイルサーバ１０-1では、それ以前に受け付けた当該ファイル６１１に対する読み出し要求の処理が進み、当該ファイル６１１の負荷が上記第２の閾値以下となる。するとファイルサーバ１０-1上の仮想分散ファイルモジュール４１０-1は、ファイルサーバ１０-n上の仮想分散ファイルモジュール４１０-nに対して、ファイル６１１のレプリカ６１２を消去するための要求を例えばプライベート通信路５を介したサーバ間通信により送る。

【００７５】この要求を受けたファイルサーバ１０-n上の仮想分散ファイルモジュール４１０-nは、既に受け付け済みの要求に対してのみレプリカ６１２を用いて処理を行い、しかる後にレプリカ６１２と対応する負荷状況情報を消去する。一方、ファイルサーバ１０-1上の仮想分散ファイルモジュール４１０-1は、クライアント２か

らのファイル６１１に対する新たな読み出し要求があれば、それに対して応答する。

【００７６】ところで、ファイルサーバ１０-1からファイルサーバ１０-nへのファイル６１１のレプリケーションにより、当該ファイル６１１に対する読み出し要求をファイルサーバ１０-nで受け付けるようになった結果、ファイルサーバ１０-1におけるファイル６１１の負荷が第２の閾値以下となる前に、ファイルサーバ１０-nにおける当該ファイル６１１のレプリカ６１２の負荷が第１の閾値を超えることがあり得る。

【００７７】そこで、このような場合、今度はファイルサーバ１０-nがレプリカ６１２を用いて次の世代のレプリカを他の１つのサーバに生成し、即ちレプリケーションのレプリケーションを行い、そのサーバでファイル６１１に対する読み出し要求を処理させればよい。そのためには、ファイル別負荷状況情報保持部１６-i（ｉ＝１～ｎ）に保持されるファイル毎の負荷状況情報に、図７（ａ）に示したような負荷状況とレプリケーションフラグに加えて、図７（ｂ）に示すように、ファイルの世代情報を持たせるとよい。

【００７８】この場合、ある世代のレプリカの負荷が上記第２の閾値以下に下がった時点で、当該レプリカを持つサーバから、そのサーバによるレプリケーションの対象となったサーバの持つ次世代のレプリカを消去する等の制御を行うことができる。このとき、レプリカの消去が要求されたサーバが、別のサーバに対して更に次世代のレプリカを生成している場合、その更に次世代のレプリカを消去するとよい。この他に、少なくともレプリカに関連したファイルの負荷状況情報については、前記したサーバ情報と同様に、各サーバ間の一致化を図ることにより、同一ファイル（レプリカを含む）について、負荷が最も低いファイルを持つサーバが、当該ファイルに対する読み出し要求に応答するようにしてもよい。

【００７９】最近では、ビデオ、オーディオ等のストリーミングデータや、或いはWWW（World Wide Web）のコンテンツ等、基本的には読み出しが主で、比較的サイズが大きく、ある程度のレスポンス（場合によっては帯域保証）が必要なデータが増加しつつある。しかもこうしたデータは、短期的に見て特定のデータ（ファイル）にアクセスが集中するケースが想定されるため、レスポンスを確保するのが困難な場合もある。以上に述べた図６の構成は、こうした状況を想定したもので、特定のファイルにアクセスが集中した場合に、自動的に当該ファイルのレプリケーションを行うことで、当該ファイルへのアクセスを分散させることができるようにしている。この構成は、単に負荷分散だけでなく、例えば重要性の高いファイルのバックアップに利用することも可能である。

【００８０】［第５の実施形態］図８は本発明の第５の実施形態に係る仮想分散ファイルサーバシステムを適用するコンピュータ・ネットワークシステムの構成を示すブロック図であり、図４と同一部分には同一符号を付してある。

【００８１】図８において、８は図４中の仮想分散ファイルサーバシステム４に相当する仮想分散ファイルサーバシステムである。この仮想分散ファイルサーバシステム８の特徴は、ファイルサーバ１０-1～１０-n、及びストレージ装置１２-1～１２-nが、例えばＦＣ－ＡＬ（Fibre Channnel Arbitrated Loop）８０により相互接続され、（ホストとしての）各ファイルサーバ１０-1～１０-nから（ターゲットとしての）ストレージ装置１２-1～１２-nの共有が可能な（つまりマルチホスト可能な）ネットワーク構成を適用している点にある。ここでは、図４の構成と異なって、プライベート通信路５を持たない点に注意されたい。

【００８２】この図８の構成では、図４の構成において（仮想分散ファイルモジュール４１０-1～４１０-nの通信モジュール４１３-1～４１３-nにより）プライベート通信路５を介して行われるサーバ間通信を、図１の構成と同様にネットワーク３を介して行えばよい（図は、この状態が示されている）。また、上記サーバ間通信を、ファイルサーバ１０-1～１０-nのストレージ接続用のインタフェースを介してＦＣ－ＡＬ８０上で行うようにしてもよい。この場合、プライベート通信路５を用いたのと同様に、ネットワーク３の負荷を軽減できる。

【００８３】図８の構成によれば、ストレージ装置１２-1～１２-nが全てのファイルサーバ１０-1～１０-nから直接に見えるので、各サーバ１０-1～１０-nに図６中のファイル別負荷状況情報保持部１６-1～１６-nを持たせることで、前記第４の実施形態で述べたようなレプリケーション動作や負荷分散を容易に行うことができる。なお、マルチホスト可能なネットワーク（インタフェース）はＦＣ－ＡＬ８０に限るものではなく、ＳＣＳＩ（Small Computer System Interface）バスであっても構わない。

【００８４】

【発明の効果】以上詳述したように本発明によれば、ネットワーク上に分散した複数のファイルサーバを、クライアントからは単一のサーバとして扱うことができ、サーバ台数やストレージ装置の接続状態をクライアントに意識させることがない。

【００８５】また本発明によれば、サーバを増設した場合、動的にボリュームを拡張することもできる。

【００８６】更に本発明によれば、複数のサーバ間で自律的な負荷分散が実現できる。

【図面の簡単な説明】

【図１】本発明の第１の実施形態に係る仮想分散ファイルサーバシステムを適用するコンピュータ・ネットワークシステムの構成を示すブロック図。

【図２】図１中のマッピングテーブルのデータ構造例を

示す図。

【図３】図１中のサーバ情報保持部のデータ構造例を示す図。

【図４】本発明の第２の実施形態に係る仮想分散ファイルサーバシステムを適用するコンピュータ・ネットワークシステムの構成を示すブロック図。

【図５】本発明の第３の実施形態に係る仮想分散ファイルサーバシステムを適用するコンピュータ・ネットワークシステムの構成を示すブロック図。

【図６】本発明の第４の実施形態に係る仮想分散ファイルサーバシステムを適用するコンピュータ・ネットワークシステムの構成を示すブロック図。

【図７】図６中のファイル別負荷状況情報保持部のデータ構造例を示す図。

【図８】同実施形態の動作を説明するタイミングチャート。

【符号の説明】

１，４，６，８…仮想分散ファイルサーバシステム

２…クライアント

３…ネットワーク

５…プライベート通信路

１０-1～１０-n…ファイルサーバ

１１，４１，６１…仮想分散ファイルシステム

１２-1～１２-n…ストレージ装置

１３-1～１３-n…ローカルファイルシステム

１４-1～１４-n…マッピングテーブル

１５-1～１５-n…サーバ情報保持部

１６-1～６-n…ファイル別負荷状況情報保持部

８０…ＦＣ－ＡＬ（マルチホスト可能なインタフェース）

１１０-1～１１０-n，４１０-1～４１０-n…仮想分散ファイルモジュール（管理モジュール）

１１１-1～１１１-n…仮想分散ファイルインタフェース

１１２-1～１１２-n…ローカルファイルインタフェース

１１３-1～１１３-n…通信モジュール

６１１…ファイル

６１２…（ファイル６１１の）レプリカ

【図１】

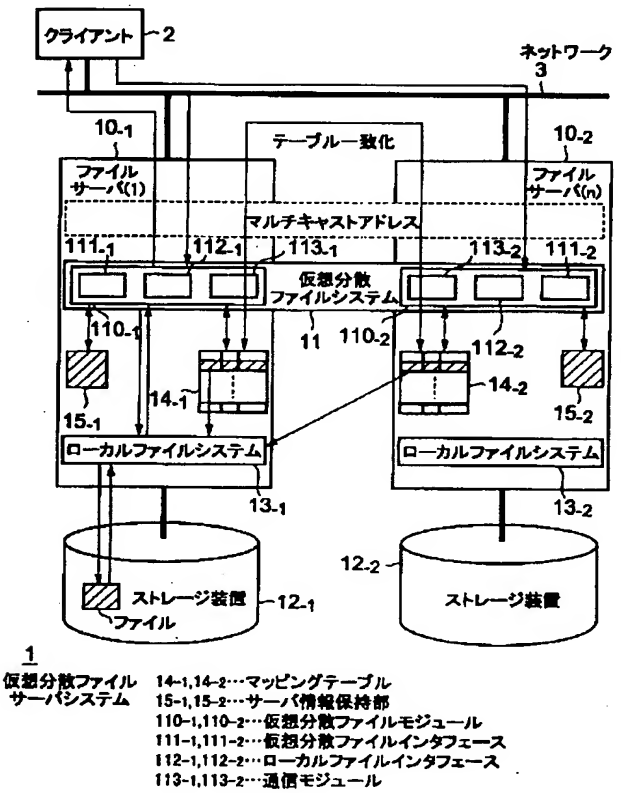

【図２】

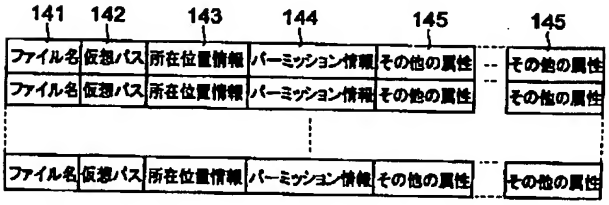

【図３】

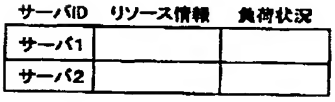

【図４】

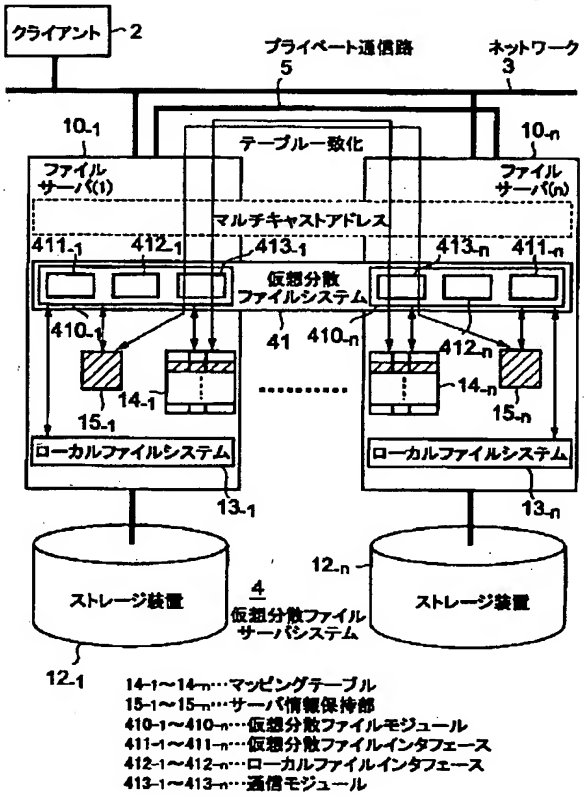
クライアント 2
プライベート通信路 5
ネットワーク 3
10-1
10-n
テーブル一致化
ファイルサーバ(1)
ファイルサーバ(n)
マルチキャストアドレス
411-1
412-1
413-1
413-n
411-n
仮想分散ファイルシステム
410-1
41
410-n
412-n
14-1
14-n
15-1
15-n
ローカルファイルシステム
13-1
13-n
12-n
ストレージ装置
4
仮想分散ファイルサーバシステム
12-1
14-1～14-n…マッピングテーブル
15-1～15-n…サーバ情報保持部
410-1～410-n…仮想分散ファイルモジュール
411-1～411-n…仮想分散ファイルインタフェース
412-1～412-n…ローカルファイルインタフェース
413-1～413-n…通信モジュール

【図６】

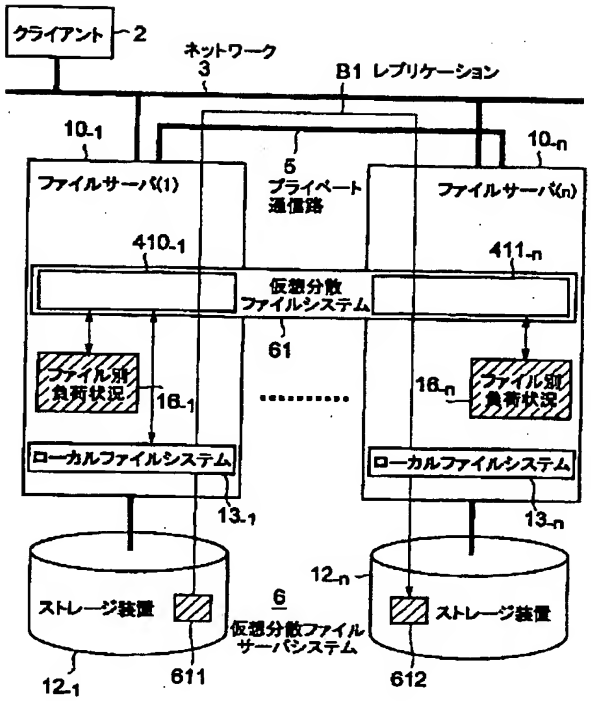
クライアント 2
ネットワーク 3
B1 レプリケーション
10-1
10-n
5
プライベート通信路
ファイルサーバ(1)
ファイルサーバ(n)
410-1
411-n
仮想分散ファイルシステム
61
ファイル別負荷状況
16-1
16-n
ローカルファイルシステム
13-1
13-n
12-n
ストレージ装置
6
仮想分散ファイルサーバシステム
12-1
611
612

【図７】

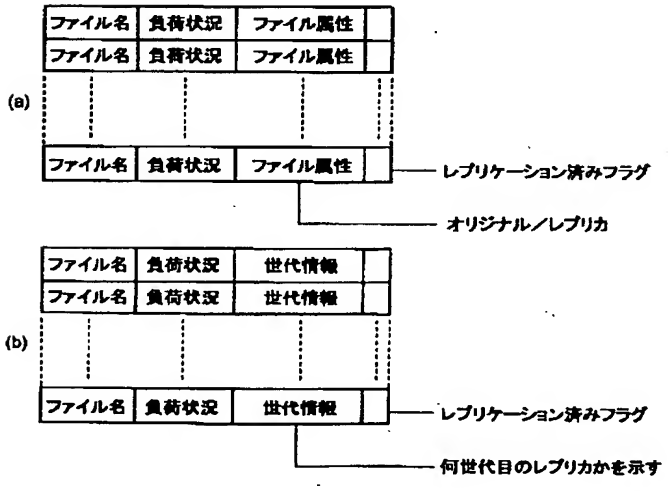
(a)
ファイル名
負荷状況
ファイル属性
レプリケーション済みフラグ
オリジナル／レプリカ
(b)
世代情報
何世代目のレプリカかを示す

【図８】

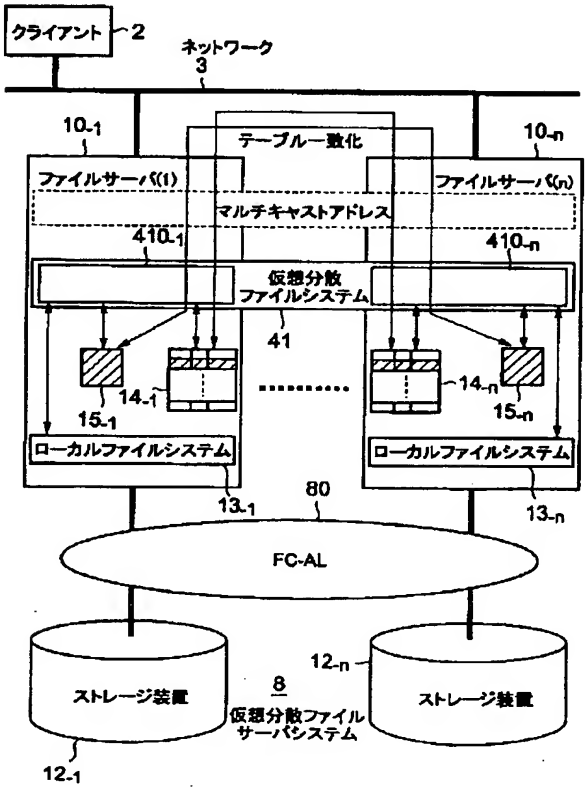
クライアント 2
ネットワーク 3
10-1
10-n
テーブル一致化
ファイルサーバ(1)
ファイルサーバ(n)
マルチキャストアドレス
410-1
410-n
仮想分散ファイルシステム
41
14-1
14-n
15-1
15-n
ローカルファイルシステム
13-1
13-n
80
FC-AL
12-n
ストレージ装置
8
仮想分散ファイルサーバシステム
12-1

【図５】

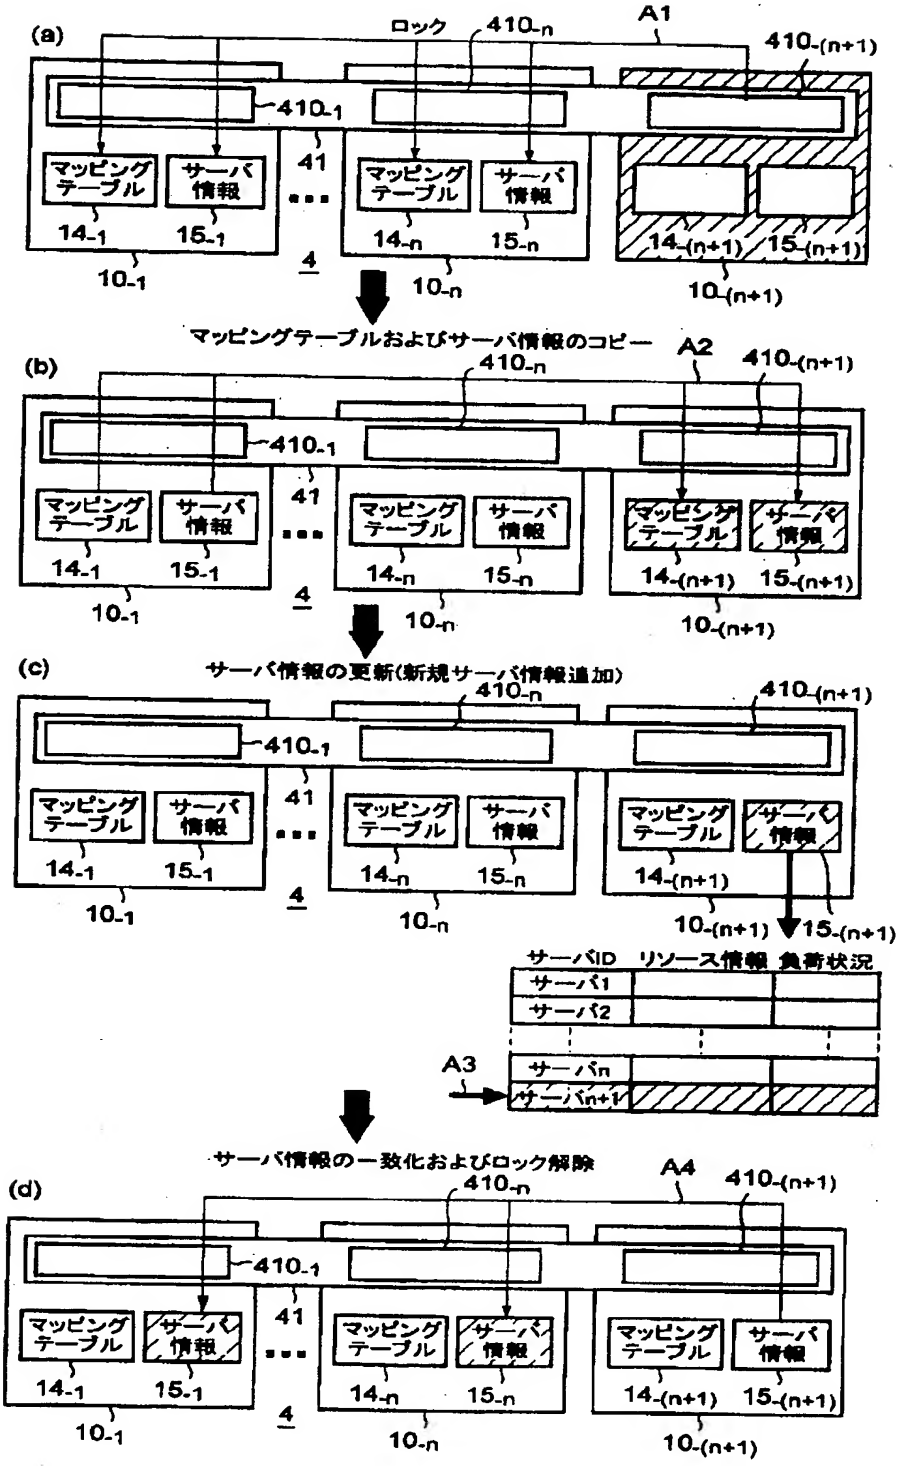
(a)
ロック
410-n
A1
410-(n+1)
410-1
マッピングテーブル
サーバ情報
41
14-1
15-1
14-n
15-n
14-(n+1)
15-(n+1)
10-1
4
10-n
10-(n+1)
マッピングテーブルおよびサーバ情報のコピー
(b)
A2
(c)
サーバ情報の更新(新規サーバ情報追加)
サーバID
リソース情報
負荷状況
サーバ1
サーバ2
サーバn
サーバn+1
A3
サーバ情報の一致化およびロック解除
(d)
A4

フロントページの続き

Ｆターム(参考) 5B082 CA18 EA07 HA03 HA05 HA08
HA09
5B089 GA12 JA11 JB15 KA00 KC15
KC28 KE07

PATENT ABSTRACTS OF JAPAN

(11)Publication number : 2000-207370
(43)Date of publication of application : 28.07.2000

(51)Int.Cl. G06F 15/177
G06F 12/00
G06F 15/16

(21)Application number : 11-011513
(22)Date of filing : 20.01.1999

(71)Applicant : MATSUSHITA ELECTRIC IND CO LTD
(72)Inventor : SATO MASAKI
UESUGI AKIO
YASUKOCHI RYUJI
TANAKA NORIKO

(54) DISTRIBUTED FILE MANAGEMENT DEVICE AND DISTRIBUTED FILE MANAGEMENT SYSTEM

(57)Abstract:
PROBLEM TO BE SOLVED: To provide a distributed film management system which can make appropriate load distribution by means of plural server computers for generating, referring to and updating files.
SOLUTION: A distributed file management system is provided with server computers A, B, and C, client computer groups 108-110, and a network 101. The server computer A 105 is constituted of a storage device 115 which records partial files, a network interface 113, a partial file management section 111 which controls the write and read of the partial files, a status management section 114 which holds load information, and a distributed file management section 112. Since the arrangement of the partial files is determined, based on the load information of each server computer A, B, and C, the concentration of loads to a specific server computer can be avoided.

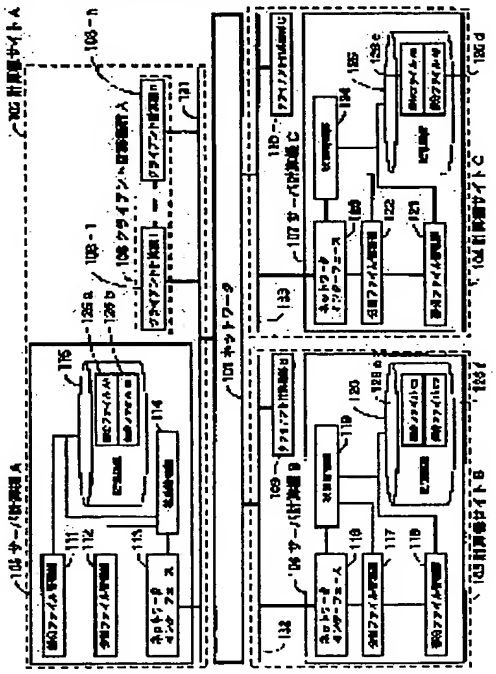

LEGAL STATUS

[Date of request for examination] 29.01.2002
[Date of sending the examiner's decision of rejection]
[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]
[Date of final disposal for application]
[Patent number]
[Date of registration]
[Number of appeal against examiner's decision of rejection]
[Date of requesting appeal against examiner's decision of rejection]
[Date of extinction of right]

* NOTICES *

1. This document has been translated by computer.So the translation may not reflect the original precisely.
2. **** shows the word which can not be translated.
3.In the drawings, any words are not translated.

CLAIMS

[Claim(s)]
[Claim 1] Distributed file management equipment connected to the network where two or more server computers, 1, or two or more client computers which have a storage means characterized by providing the following to memorize data are connected. The state management tool which holds and manages the load information on two or more aforementioned server computers. A distributed file management means to determine the server computer which processes the aforementioned partial file based on the aforementioned load information which specifies the partial file of the aforementioned distributed file and is managed with the aforementioned state management tool corresponding to the processing demand of the distributed file from the aforementioned client computer.
[Claim 2] The aforementioned state management tool is distributed file management equipment according to claim 1 characterized by what it has for the external state management tool which holds the load information on the server computer which notified the aforementioned load information to other distributed file management equipments, and was notified from other distributed file management equipments as external load information.
[Claim 3] The aforementioned external state management tool is distributed file management equipment according to claim 2 characterized by what multicasting notifies the aforementioned load information for to distributed file management equipment besides the above.
[Claim 4] The aforementioned external state management tool is distributed file management equipment according to claim 2 or 3 characterized by what the aforementioned load information is notified for to other distributed file management equipments which adjoin among distributed file management equipment besides the above.
[Claim 5] Distributed file management system equipped with the network which connects two or more server computers characterized by providing the following, 1 or two or more client computers, two or more aforementioned server computers and the above 1, or two or more client computers. Each of two or more aforementioned server computers is a storage means to memorize the partial file which constitutes a part or all of a distributed file. A distributed file management means to determine the state management tool which holds and manages load information, and the server computer which processes the aforementioned partial file based on the aforementioned load information which specifies the partial file of the aforementioned distributed file and is managed with the aforementioned state management tool corresponding to the processing demand of the distributed file from the aforementioned client computer.
[Claim 6] the aforementioned state management tool notified the aforementioned load information to other server computers, and was notified from other server computers -- being concerned -- others -- the distributed file management system according to claim 5 characterized by what it has for the external state management tool which holds the load information on a server computer as external load information
[Claim 7] The aforementioned external state management tool is distributed file management system according to claim 6 characterized by what multicasting notifies the aforementioned load information for to a server computer besides the above.
[Claim 8] It is the distributed file management system according to claim 6 or 7 characterized by what the aforementioned external state management tool notifies the aforementioned load information for to other server computers which belong to a predetermined server computer group among the above 1 or two or more server computer groups by carrying out the group division of two or more aforementioned server computers at 1 or two or more server computer groups.
[Claim 9] It is the distributed file management system according to claim 6 or 7 characterized by what the aforementioned external state management tool notifies the aforementioned load information for to other server computers belonging to the server computer group which adjoins among the above 1 or two or more server computer groups by carrying out the group division of two or more aforementioned server computers at 1 or two or more server computer groups.
[Claim 10] The aforementioned distributed file-management means is distributed file management system the distributed file-management equipment according to claim 2 to 4 characterized by what other server computers of a partial file and a movement place which move based on the access information for every aforementioned partial file, the aforementioned load information, and the aforementioned external load information are determined, and it has a distributed file move means move this partial file to this server computer for, 6, or given in nine.
[Claim 11] The aforementioned distributed file move means is the distributed file-management equipment according to claim 10 or the distributed file management system carry out what the load of the aforementioned storage means included in the aforementioned load information detects that it is size rather than a predetermined value, other server computers of a partial file and a movement place which move based on the aforementioned external load information and the aforementioned access information determine, and this partial file moves for to these server computers of other as the feature.
[Claim 12] The aforementioned distributed file move means is the distributed file-management equipment according to claim 10 or the distributed file management system carry out what the remaining capacity of the aforementioned storage means included in the aforementioned load information detects that it is smallness from a predetermined value, and determines other server computers of a partial file and a movement place which move based on the aforementioned external load information and the aforementioned access information, and this partial file moves for to these server computers of other as the feature.
[Claim 13] The aforementioned distributed file move means is the distributed file-management equipment according to claim 10 or the distributed file management system which carries out as the feature in what the load of the aforementioned network included in the aforementioned load information detects that it is size rather than a predetermined value, other server computers of a partial file and a movement place which move based on the aforementioned external load information and the aforementioned access information determine, and this partial file moves to these server computers of other for.
[Claim 14] The aforementioned distributed file move means The aforementioned load information, the aforementioned external load information, the aforementioned access information, And it is based on the initial entry between the aforementioned client computer and two or more aforementioned server computers. It asks for the communication cost between the server computer which has a storage means to hold the aforementioned partial file, and the client computer which performed the processing demand. Distributed file management equipment according to claim 10 or distributed file management system characterized by what other server computers which serve as communication cost of smallness from this communication cost are determined, and the aforementioned partial file is moved for to these server computers of other.
[Claim 15] The aforementioned distributed file move means is the distributed file management equipment according to claim 10 to 14 or distributed file management system characterized by what it checks beforehand whether movement of the aforementioned partial file is possible for to the server computer besides the above used as the movement place of the aforementioned partial file.
[Claim 16] The aforementioned distributed file move means is the distributed file management equipment according to claim 10 to 15 or distributed file management system characterized by what other partial files are moved for to the aforementioned server computer from a server

http://www4.ipdl.jpo.go.jp/cgi-bin/tran_web_cgi_ejje?u=http%3A%2F%2Fwww6.ipdl.jp... 2003/07/22

computer besides the above when the aforementioned partial file is moved to a server computer besides the above.
[Claim 17] The aforementioned distributed file move means is the distributed file management equipment according to claim 10 to 16 or distributed file management system which makes a list the candidate of other server computers which can move the aforementioned partial file, and is characterized by what other server computers which move the aforementioned partial file are determined for based on this list.
[Claim 18] The aforementioned distributed file move means is the distributed file management equipment according to claim 10 to 17 or distributed file management system characterized by what the information about the server computer which created the aforementioned partial file with movement of the aforementioned partial file is sent for to a server computer besides the above.
[Claim 19] The aforementioned distributed file-management means is distributed file-management equipment or distributed file management system the claim 2 characterized by what other server computers of a partial file and a copy place to copy determine based on the access information for every aforementioned partial file, the aforementioned load information, and the aforementioned external load information, and it has a distributed file copy means copy the aforementioned partial file to a server computer besides the above for, 4 and 6, or given in 18.
[Claim 20] The aforementioned distributed file copy means is the distributed file-management equipment according to claim 19 or the distributed file management system characterized by what the load of the aforementioned storage means included in the aforementioned load information detects that it is size, determines other server computers of a partial file and a copy place which copy based on the aforementioned external load information and the aforementioned access information, and copies this partial file for to these server computers of other rather than a predetermined value.
[Claim 21] The aforementioned distributed file copy means is the distributed file-management equipment according to claim 19 or the distributed file management system characterized by what the load of the aforementioned network included in the aforementioned load information detects that it is size, determines other server computers of a partial file and a movement place copied based on the aforementioned external load information and the aforementioned access information, and copies this partial file for to these server computers of other rather than a predetermined value.
[Claim 22] The aforementioned distributed file copy means The aforementioned load information, the aforementioned external load information, It is based on the aforementioned access information and the initial entry between the aforementioned client computer and two or more aforementioned server computers. It asks for the communication cost between the server computer which has a storage means to hold the aforementioned partial file, and the client computer which performed the processing demand. Distributed file management equipment according to claim 19 or distributed file management system characterized by what other server computers which serve as communication cost of smallness from this communication cost are determined, and the aforementioned partial file is copied for to these server computers of other.
[Claim 23] The aforementioned distributed file copy means is the distributed file management equipment according to claim 19 to 22 or distributed file management system characterized by what it checks beforehand whether the copy of the aforementioned partial file is possible for to the server computer besides the above used as the copy place of the aforementioned partial file.

[Claim 24] The aforementioned distributed file copy means is the distributed file management equipment according to claim 19 to 23 or distributed file management system characterized by what other partial files are copied for to the aforementioned server computer from a server computer besides the above when the aforementioned partial file is copied to a server computer besides the above.
[Claim 25] The aforementioned distributed file copy means is the distributed file management equipment according to claim 19 to 24 or distributed file management system which makes a list the candidate of other server computers which can copy the aforementioned partial file, and is

characterized by what other server computers which copy the aforementioned partial file are determined for based on this list.
[Claim 26] The aforementioned distributed file copy means is the distributed file management equipment according to claim 19 to 25 and distributed file management system which are characterized by what other server computers of two or more copy places which copy the aforementioned partial file are chosen, and the aforementioned partial file is simultaneously copied for to two or more of other aforementioned selected server computers by multicasting.
[Claim 27] The aforementioned load information managed with the aforementioned state management tool is the distributed file management equipment according to claim 1 to 26 or distributed file management system characterized by what the capacity of the aforementioned storage means, a load, and the communication load between the aforementioned network and two or more aforementioned server computers are included for.
[Claim 28] Furthermore, the aforementioned server computer is the distributed file management equipment according to claim 1 to 27 or distributed file management system characterized by what it has for the partial file management means which writes the aforementioned partial file in the aforementioned storage means, and reads the aforementioned partial file from the aforementioned storage means.
[Claim 29] When the aforementioned processing demand from the aforementioned client computer is a creation demand of a distributed file, the aforementioned distributed file management means Divide this distributed file into two or more partial files, and the server computer holding the partial file which divided is determined based on the aforementioned load information managed with the aforementioned state management tool. When the aforementioned processing demand from the aforementioned client computer is a reference demand or updating demand of a distributed file The existence of a partial file set as the object of processing of the aforementioned reference demand or the aforementioned updating demand is decided.
Distributed file management equipment according to claim 1 to 28 or distributed file management system characterized by what the server computer which processes the aforementioned processing demand is determined for based on the aforementioned load information managed with the aforementioned state management tool.
[Claim 30] The aforementioned distributed file management means is the distributed file management equipment according to claim 1 to 29 or distributed file management system characterized by what it has a partial file size determination means to determine the size of the aforementioned partial file which constitutes a part or all of a distributed file for based on the information from the aforementioned client computer.
[Claim 31] The aforementioned distributed file management means is the distributed file management equipment according to claim 1 to 29 or distributed file management system characterized by what it has a partial file size determination means to determine the size of the aforementioned partial file which constitutes a part or all of the aforementioned distributed file for based on the kind of data currently recorded on the distributed file.

[Translation done.]

* NOTICES *

1.This document has been translated by computer. So the translation may not reflect the original precisely.
2.**** shows the word which can not be translated.
3.In the drawings, any words are not translated.

DETAILED DESCRIPTION

[Detailed Description of the Invention]
[0001]
[The technical field to which invention belongs] this invention relates to the distributed file management equipment and distributed file management system which distribute and manage a file to two or more terminals in a computer network system. In the server client type computer network system which connected two or more server computers and client computers especially in the network, it is related with the distributed file management equipment and distributed file management system which distribute and manage a file by two or more server computers.
[0002]
[Description of the Prior Art] There is a distributed file system currently indicated by for example, JP,8-77054,A public relations as distributed file management technology applied to the server client type computer network system (only henceforth a "network system") which connected two or more server computers and client computers in the network from the former.
[0003] Drawing 30 shows the conventional distributed file system currently indicated by JP,8-77054,A public relations. This conventional distributed file system is equipped with the network 3001 which connects two or more server computers 3002, 3003, 3004, and 3005, two or more client computers 3006, 3007, and 3008, and the server computers 3002, 3003, 3004, and 3005 and two or more client computers 3006, 3007, and 3008 of these plurality in drawing 30 .
[0004] Here, the partial file B-1 (3002-3) of the partial file A-1 (3002-1) of the distributed file A and the distributed file B is held at the server computer 3002. Moreover, the partial file B-2 (3003-2) of the partial file A-2 (3003-1) of the distributed file A and the distributed file B is held at the server computer 3003. Moreover, the partial file B-3 (3004-2) of the partial file A-3 (3004-1) of the distributed file A and the distributed file B is held at the server computer 3004.
[0005] Moreover, the server computer 3005 is equipped with each partial file A-1 to A-3 currently held at each server computers 3002, 3003, and 3004, and the distributed file management section 3005-2 which manages B-1 to B-3. Reference/updating demand distribution information 3005-1 for performing the distribution to a reference demand or updating demand (only henceforth "reference/updating demand") of the partial file from the client computers 3006, 3007, and 3008 is held.
[0006] The distributed file creation section 3006-1 in which the client computer 3006, on the other hand, creates the partial file of a distributed file according to a distributed file creation demand. The updating demand distribution section 3006-2 which determines the whereabouts of the partial file of this distributed file based on reference/updating demand distribution information 3005-1 on the server computer 3005 according to the updating demand to a distributed file. According to the reference demand to a distributed file, it has the reference demand distribution section 3006-3 which determines the whereabouts of the partial file of this distributed file based on reference/updating demand distribution information 3005-1 on the server computer 3005. In addition, other client computers 3007 and 3008 have same composition.
[0007] According to the conventional distributed file system mentioned above, when the user of the client computer 3006 demands creation of a distributed file, the distributed file creation section 3006-1 of the client computer 3006 determines the server computer which creates the partial file of the distributed file concerned based on the distribution conditions decided beforehand, and creates the partial file of a distributed file to this server computer, for example. And reference/updating demand distribution information 3005-1 that it expresses with which server computer whether the partial file was created simultaneously with creation of this partial file is generated. It is transmitted to the server computer 3005 through a network 3001, and this reference/updating demand distribution information 3005-1 is held by the server computer 3005.

[0008] Moreover, when the user of the client computer 3006, for example, performs reference/updating demand which refers to or updates a distributed file, the client computer 3006 performs the open demand of the corresponding distributed file first to the distributed file management section 3005-2 of the server computer 3005. The distributed file management section 3005-2 of the server computer 3005 transmits reference/updating demand distribution information 3005-1 about the distributed file concerned to the client computer 3006 through a network 3001 corresponding to the open demand of the distributed file from the client computer 3006. The updating demand distribution section 3006-2 of the client computer 3006 or the reference demand distribution section 3006-3 transmits reference/updating demand to the server computer holding the partial file of a distributed file based on reference/updating demand distribution information 3005-1 received from the server computer 3005.
[0009] Thus, in the conventional distributed file system, when two or more processing demands concentrate to one distributed file by dividing a distributed file into two or more partial files, and distributing the processing (creation, reference, updating) to a distributed file to processing of a partial file unit, a load can be distributed, without centralizing a load on one server computer.
[0010]
[Problem(s) to be Solved by the Invention] However, in the conventional distributed file system as shown in drawing 30 , since the server computer which creates this partial file is determined based on the fixed distribution rule decided beforehand in case the partial file which constitutes a distributed file is created, it is not what took into consideration the load information on a realistic server computer in distribution of the file to a server computer. For this reason, the creation demand of a partial file may occur further to the server computer which access and processing concentrate and is high [a load] in fact. Therefore, the load of only a specific server computer may become large and there was a problem that a suitable load distribution was not performed by two or more server computers.
[0011] Moreover, it sets to the conventional distributed file system. Once it distributes a partial file to a server computer fixed based on the above-mentioned distribution rule After creation of a partial file after the distribution (i.e., the server computer which was able to be distributed) In order not to perform movement or the copy of a partial file which were created, when access to a specific partial file concentrated, there was a problem that the load by access could not be distributed.
[0012] Therefore, the purpose of this invention is offering the distributed file management equipment and distributed file management system which can perform a suitable load distribution by two or more server computers in creation of a file, reference, and updating.
[0013]
[Means for Solving the Problem] In order to solve the above-mentioned technical problem, the distributed file management equipment of the 1st mode concerning this invention It is distributed file management equipment connected to the network where two or more server computers, 1, or two or more client computers which have a storage means to memorize data are connected. The state management tool which holds and manages the load information on two or more server computers, Corresponding to the processing demand of the distributed file from client computer, the partial file of a distributed file is specified and it is characterized by having a distributed file management means to determine the server computer which processes a partial file, based on the load information managed with the state management tool.
[0014] In the distributed file management equipment concerning an above-mentioned this invention A state management tool can also be equipped with the external state management

http://www4.ipdl.jpo.go.jp/cgi-bin/tran_web_cgi_ejje 2003/07/22

tool which holds the load information on the server computer which notified load information to other distributed file management equipments, and was notified from other distributed file management equipments as external load information.
[0015] You may make it an external state management tool notify load information to other distributed file management equipments by multicasting here. Moreover, an external state management tool can also notify load information to other distributed file management equipments which adjoin among other distributed file management equipments.
[0016] In order to solve the above-mentioned technical problem, moreover, the distributed file management system of the 1st mode concerning this invention In the distributed file management system equipped with the network which connects two or more server computers, 1 or two or more client computers, two or more server computers and 1, or two or more client computers Each of two or more server computers A storage means to memorize the partial file which constitutes a part or all of a distributed file, State management tool which holds and manages load information It corresponds to the processing demand of the distributed file from a client computer. The partial file of a distributed file is specified and it is characterized by having a distributed file management means to determine the server computer which processes a partial file, based on the load information managed with the state management tool.
[0017] the distributed file management system concerning an above-mentioned this invention -- setting -- the state management tool notified load information to other server computers, and was notified from other server computers -- being concerned -- others -- you may make it have the external state management tool which holds the load information on a server computer as external load information Here, an external state management tool can also notify load information to other server computers by multicasting.
[0018] Moreover, it sets to the distributed file management equipment and distributed file management system concerning an above-mentioned this invention. Two or more server computers The group division is carried out at 1 or two or more server computer groups. An external state management tool You may make it notify load information to other server computers which belong to a predetermined server computer group among 1 or two or more server computer groups. Or you may make it an external state management tool notify the aforementioned load information to other server computers belonging to the server computer group which adjoins among 1 or two or more server computer groups.
[0019] Furthermore, a distributed file management means can determine other server computers of a partial file and a movement place which move based on the access information, load information, and external load information for every partial file, and can also be equipped with a distributed file move means to move this partial file to this server computer.
[0020] A distributed file move means detects that it is size here rather than a value predetermined in the load of the storage means included in load information. Other server computers of a partial file and a movement place which move based on external load information and access information are determined. this partial file -- these server computers of other -- moving -- you may make -- Or a distributed file move means detects that it is smallness from a value predetermined in the remaining capacity of the storage means included in load information. Other server computers of a partial file and a movement place which move based on external load information and access information are determined, and you may make it move this partial file to these server computers of other. Moreover, a distributed file move means detects that it is size rather than a value predetermined in the load of the network included in load information. other server computers of a partial file and a movement place which move based on external load information and access information -- determining -- this partial file -- these server computers of other -- it can also move -- A distributed file move means Or load information, external load information, access information, And it is based on the initial entry between a client computer and two or more server computers. It asks for the communication cost between the server computer which has a storage means to hold the partial file, and the client computer which performed the processing demand, other server computers which serve as communication cost of smallness from this communication cost are determined, and you may make it move a partial file to these server computers of other.

[0021] Furthermore, a distributed file move means can also check beforehand whether movement of the aforementioned partial file is possible to other server computers used as the movement place of a partial file. When a distributed file move means moves a partial file to other server computers, it can also move other partial files to a server computer from other server computers again. Furthermore, a distributed file move means makes a list the candidate of other server computers which can move a partial file, and you may make it determine other server computers which move a partial file based on this list. Moreover, a distributed file move means can send the information about the server computer which created the partial file with movement of a partial file to other server computers.
[0022] Moreover, an above-mentioned distributed file management means can determine other server computers of a partial file and a copy place to copy based on the access information, load information, and external load information for every partial file, and can also be equipped with a distributed file copy means to copy a partial file to other server computers.
[0023] At this time, a distributed file copy means detects that it is size rather than a value predetermined in the load of the storage means included in load information. Other server computers of a partial file and a copy place copied based on external load information and access information are determined. You may make it copy this partial file to these server computers of other. A distributed file copy means The load of the network included in load information detects that it is size, and determines other server computers of a partial file and a movement place copied based on external load information and access information, and you may make it copy this partial file to these server computers of other rather than a predetermined value. Or a distributed file copy means asks for the communication cost between the server computer which has a storage means hold the partial file, and the client computer which performed the processing demand based on load information, external load information, access information, and the initial entry between a client computer and two or more server computers, determines other server computers which serve as communication cost of smallness from this communication cost, and can copy a partial file to these server computers of other.
[0024] Here, as for a distributed file copy means, it is good to check beforehand whether the copy of a partial file is possible to other server computers used as the copy place of a partial file. Moreover, when a distributed file copy means copies a partial file to other server computers, it may copy other partial files to a server computer from other server computers. Moreover, a distributed file copy means makes a list the candidate of other server computers which can copy a partial file, and can determine other server computers which copy a partial file based on this list. Furthermore, a distributed file copy means can choose other server computers of two or more copy places which copy a partial file, and can also copy a partial file to two or more of other selected server computers simultaneously by multicasting.
[0025] Moreover, the load information managed with the state management tool can contain the capacity of a storage means, a load, and the communication load between a network and two or more server computers.
[0026] Furthermore, it sets to the distributed file management equipment and distributed file management system concerning an above-mentioned this invention. A server computer can also be equipped with the partial file management means which writes a partial file in a storage means, and reads a partial file from a storage means.
[0027] Moreover, distributed file management means When the processing demand from a client computer is a creation demand of a distributed file Divide this distributed file into two or more partial files, and the server computer holding the partial file which divided is determined based on the load information managed with the state management tool. When the processing demand from client computer is a reference demand or updating demand of a distributed file the existence of a partial file set as the object of processing of a reference demand or an updating demand is decided, and the server computer which processes a processing demand is determined based on the load information managed with the state management tool -- you may make it like
[0028] Moreover, a distributed file-management means can have a partial file size determination means determine the size of the partial file which constitutes a part or all of a distributed file,

based on the information from a client computer. Or a partial file size determination means determine the size of the partial file which constitutes a part or all of a distributed file may make a distributed file-management means have based on the kind of data currently recorded on the distributed file.

[0029] In the distributed file management equipment and distributed file management system concerning an above-mentioned this invention, since the server computer by which a distributed file management means arranges a partial file based on the load information on a server computer is determined, concentration of the load to a specific server computer is avoidable.

[0030] Moreover, since the server computer by which a distributed file management means arranges a partial file based on the load information on other server computers is determined, it is avoidable that a load concentrates by the specific server computer.

[0031] Moreover, the imbalance of concentration of the load to the storage means of a specific server computer and the capacity of a storage means is avoidable by moving a partial file to other server computers. Moreover, concentration of the load to the storage of a specific server computer is avoidable by copying a partial file to other server computers.

[0032] Moreover, since the size of the partial file which constitutes a distributed file can be changed suitably, it is avoidable to divide into two or more partial files the data which have relation logically and in content, for example, the data for one picture etc.

[0033]

[Embodiments of the Invention] Hereafter, the gestalt of operation of the distributed file management equipment of this invention and distributed file management system is explained using drawing 29 from drawing 1 .

[0034] (Gestalt 1 of operation) Drawing 1 is the block diagram showing an example of the gestalt of operation of the 1st of the distributed file management system in this invention. It set to drawing 1 and this distributed file management system is equipped with the networks 101, such as a Local Area Network which connects mutually two or more computers site A102 equipped with the client computer group which consists of two or more client computers, such as server computers, such as a personal computer and a workstation, and a personal computer, and a workstation, the computer site B103 and the computer site C104, the computer site A102 and the computer site B103, and the computer site C104, and a Wide Area Network.

[0035] Here, the computer site A102 is equipped with two or more server computers (only "the server computer A105" is shown in drawing 1), such as a personal computer and a workstation, and the client computer group A108 which consists of client computer 1-n (108-1 - 108-n), such as a personal computer and a workstation. This computer site A102 has connected two or more server computers (only "the server computer A105" is shown in drawing 1) and client computer groups A108 in the internal networks 131, such as Ethernet, for example, has become the Internet domain.

[0036] Moreover, like the computer site A102, the computer site B103 was equipped with the client computer group B109 which consists of two or more server computers (only "the server computer B106" is shown in drawing 1), and two or more client computers, and the computer site C104 is equipped with the client computer group C110 which consists of two or more server computers (only "the server computer C107" is shown in drawing 1), and two or more client computers. furthermore, these computer sites B103 and the computer site C104 -- the computer site A102 -- the same -- two or more server computers (in drawing 1 , only the "server computer B106" and the "server computer C107" are shown), and the client computer groups B109 and the client computer groups C110 -- each -- it has connected in the internal network 132 and the internal network 133, for example, has become the Internet domain

[0037] The storage 115, such as a hard disk with which the server computer A105 records the partial file of a distributed file, The network interface 113 for connecting with the internal networks 131, such as Ethernet The partial file management section 111 which controls the writing and read-out to the storage 115 which is recording the partial file, With the state Management Department 114 which supervises the load to storage 115, the remaining capacity of storage 115, and the load to a network interface 113, and holds the information about such loads and capacity It is constituted by the partial file management section 111, the state

Management Department 114, and the distributed file management section 112 connected to the network interface 113.

[0038] This distributed file management section 112 directs writing and read-out of a partial file in the partial file management section 111. Moreover, when creating a distributed file, based on the information acquired from the state Management Department 114, the distributed file management section 112 divides a distributed file into two or more partial files, and determines the server computer which arranges each partial file (record). Moreover, in referring to or updating the distributed file created before, it determines the server (recorded) computer by which the partial file of the corresponding distributed file exists.

[0039] The server computer B106 and the server computer C107 have the same composition as the server computer A105. That is, the server computer B106 is constituted by storage 120, a network interface 118, the partial file management section 116, the state Management Department 119, and the distributed file management section 117. Moreover, the server computer C107 is constituted by storage 125, a network interface 123, the partial file management section 121, the state Management Department 124, and the distributed file management section 122.

[0040] Drawing 2 is drawing showing an example of the composition of a distributed file. The distributed file 201 is constituted by two or more partial files 202-1 - 202-n in drawing 2 .

[0041] In drawing 1 , the state after each distributed files A, B, and C were created is shown. That is, the partial file A1 (126a) of the distributed file A and the partial file B1 (126b) of the distributed file B are recorded on the storage 115 of the server computer A105. Moreover, the partial file C1 (126e) of the distributed file C and the partial file C2 (126f) of the distributed file C are recorded on the storage 120 of the server computer B106. Moreover, the partial file A2 (126c) of the distributed file A and the partial file A3 (126d) of the distributed file A are recorded on the storage 125 of the server computer C107.

[0042] Next, operation of the distributed file management system constituted as mentioned above is explained. The creation demand of the distributed file A is published to the server computer A105 from the client computer 1 (108-1) of the client computer group A108 below, and distributed processing in case the partial files A1-A3 as shown in drawing 1 are created is made into an example, and is explained. Here, the storage 115, 120, and 125 shown in drawing 1 shall have two or more storage sections or storage regions (only henceforth the "storage section"), respectively. Two or more of these storage sections may be one record medium physically, and may be two or more record media.

[0043] In drawing 1 , the creation demand of the distributed file A is first published by the server computer A105 from the client computer 1 (108-1). The creation demand of this distributed file A is received by the distributed file management section 112 of the server computer A105 through the network interface 113 of the internal network 131 and the server computer A105.

[0044] Drawing 3 is a flow chart which shows the algorithm of the distributed file management section at the time of receiving the creation demand of a distributed file of operation. Hereafter, detailed operation of the distributed file management section 112 is explained using drawing 1 and drawing 3 .

[0045] The distributed file management section 112 which received the creation demand of the distributed file A acquires first the load information which the state Management Department 114 has managed (Step 301).

[0046] Drawing 4 is drawing showing the load information table 401 managed at the state Management Department 114. In drawing 4 , the load information table 401 consists of the storage load information network load information table 402 and 403.

[0047] This storage load information table 402 consists of items of the "remaining capacity" which indicates the remaining capacity [Mbytes] of each storage section to be the "load" which indicates the load information on each storage section [%] to be the "storage identifier" for discriminating two or more storage sections of the storage 115 connected to the server computer A105. Here, the "load" of each storage section of storage 115 shows what % of the maximum transfer rates of each storage section of storage 115 is used.

[0048] Moreover, the network load information table 403 The data sent out on a network 101

through a network interface 113 [what bandwidth (use communication-band width of face [Mbps]) is used by being sent out towards which computer site (sending-out place site), and] Moreover, the received data are sent from which computer site (sending out agency site), and it is shown whether it has received using the bandwidth (use communication-band width of face [Mbps]) of how much. The item of this "sending out agency site" shows the computer site of the sending-out origin of data, and the item of a "sending-out place site" shows the computer site of the sending-out place of data. That is, in SiteA, SiteB shows the computer site B106 and SiteC shows the computer site C107 for the computer site A105. Here, a transmitting agency site and a transmission place site are named generically, and it is called a network link (only henceforth a "link"). Moreover, the item of "use communication-band width of face" shows the communication-band width of face [Mbps] currently used between the sending out agency site and the sending-out place site.

[0049] That is, when the distributed file management section 112 receives the creation demand of the distributed file A, the distributed file management section 112 acquires the information that the load of the storage section of the storage identifier DiskID1 is 20 [%], and remaining capacity is 10 [Mbytes] based on the information on the storage load information table 402 gained from the state Management Department 114, as shown in drawing 4 (Step 301).

[0050] Next, based on the information on the storage load information table 402 obtained from the state Management Department 114, out of the storage 115 connected to the server computer A105, remaining capacity fully remains, and a load chooses the low storage section from a predetermined threshold, and the distributed file management section 112 assigns the partial file in order to this storage section. Here, as a threshold, it is good to use 80 [%] etc. for example. However, this threshold can be suitably determined according to the composition of storage 115 etc. Moreover, the size of a partial file has a desirable fixed length, and it is good to make it the same size by all server computers. At this time, when all the partial files A1-A3 are assigned by the storage section of storage 115, Step 304 is processed. On the other hand, Step 303 is processed when all the partial files A1-A3 are not assigned by the storage section of storage 115 (Step 302).

[0051] in the case of the gestalt (drawing 1) of this operation, all the partial files A1-A3 are assigned to the storage section of storage 115 -- having not had (Step 302) -- the partial file A1 (126a) of the distributed file A is assigned to the server computer A105, and the remaining partial files A2 and A3 are assigned to other server computers C107

[0052] The distributed file management section 112 asks whether the partial files A2 and A3 can be created through the internal network 131 and a network 101 to other server computers, in order to assign the partial files A2 and A3 which were not assigned at Step 302 to other server computers. By other server computers which received the inquiry, the load information table 401 of the state Management Department of self is investigated, and it answers [whether creation of the partial files A2 and A3 is possible, and] (Step 303). The distributed file management section of each server computer will perform an exchange of an inquiry of creation of this partial file, and the signal of an answer through a network interface and a network.

[0053] In the case of the gestalt (drawing 1) of this operation, the distributed file management section 112 asks the distributed file management section 122 of the server computer C107 of the computer site C104 whether creation of the partial file A2 (126c) and the partial file A3 (126d) can be performed through a network interface 113 and a network 101. Based on the load information table 401 obtained from the state Management Department 124, the distributed file management section 122 of the server computer C107 performs the same judgment as the above-mentioned step 302, and answers [whether creation of the partial file A2 (126c) and the partial file A3 (126d) can be performed, and] the server computer A105 (Step 303). In the case of drawing 1 , to the storage 125 of the server computer C107, the partial file A2 (126c) and the partial file A3 (126d) can be created.

[0054] Next, the distributed file management section 112 of the server computer A registers the information for managing the partial file A1 assigned to the storage 115 of the server computer A, and the partial files A2 and A3 assigned to the storage 125 of other server computers C (Step 304).

[0055] Drawing 5 is drawing showing the distributed file control table 501. Moreover, drawing 6 is drawing showing the partial file control table 601. In drawing 5 , the distributed file control table 501 consists of items of "the partial file identification child list of [for discriminating the partial file which constitutes the "distributed file identification child" and distributed file for discriminating a distributed file]." Moreover, in drawing 6 , the partial file control table 601 consists of items of the "address" which shows the "partial file identification child" for discriminating a partial file, and the address of a partial file. Here, the "partial file identification child" who showed drawing 6 is equivalent to the "partial file identification child" who constitutes the "partial file identification child list" shown by drawing 5 .

[0056] If it sees about the distributed file A, in drawing 5 , it expresses that the distributed file A consists of a partial file A1 (126a), a partial file A2 (126c), and a partial file A3 (126d) with the case of the gestalt (drawing 1) of this operation, for example. Moreover, in drawing 6 , the address of the partial file A1 (126a) is "file://siteA/serverA/DiskID1/(storage identifier DiskID1 of the server computer A105 of the computer site A102)." The address of the partial file A2 (126c) is "file://siteC/serverC/DiskID2/(storage identifier DiskID2 of the server computer C107 of the computer site C104)." The address of the partial file A3 (126d) expresses that it is "file://siteC/serverC/DiskID2/(storage DiskID2 of the server C107 of the computer site C104)."

[0057] Next, when creating the partial file A1 to the storage 115 of the server computer A, through the partial file management section 111, the distributed file management section 112 writes the data from the client computer 1 (108-1) in storage 115, and creates the partial file A1 of the distributed file A. When recording the partial files A2 and A3 on other server computers C107, moreover, the distributed file management section 112 Request record of the partial files A2 and A3 from the distributed file management section 122 of the server computer C107 which records, and, simultaneously with it, it directs to the client computer 1 (108-1) which performed the creation demand of the distributed file A. Immediate data are transmitted to the server computer C107 which performs record from the client computer 1 (108-1). By the server computer C107 which received the request, the distributed file management section 122 registers the partial files A2 and A3 to the partial file control table 601. thus, other server computers C107 top -- the partial file A -- 2 and 3 are created (Step 305)

[0058] above -- carrying out -- creation of the partial file A1 (126a) of the distributed file A -- the data from the client computer 1 (108-1) -- the storage 115 of the server computer A105 -- ******** -- it is carried out by things Moreover, creation of the partial file A2 (126c) of the distributed file A and the partial file A3 (126d) sends the data from the client computer 1 (108-1) to the **** server computer C107, and is performed by writing in the storage 125 of the server computer C107.

[0059] Moreover, in the above-mentioned step 303, by all other server computers, when creation of a partial file is impossible, the distributed file management section 112 notifies that creation of a distributed file went wrong to the client computer 1 (108-1) which performed the creation demand of a distributed file (Step 306).

[0060] On the other hand, at Step 302, when creation of all the partial files of a distributed file is made to the storage of the server computer of self, the distributed file management section 112 is registered into the partial file control table 601 having shown the information for managing the distributed file assigned to storage 115 in the distributed file control table 501 shown in drawing 5 , and drawing 6 (Step 307).

[0061] Next, through the partial file management section 111, the distributed file management section 112 writes the data from the client computer 1 (108-1) in storage 115, and creates all partial files (Step 308).

[0062] As mentioned above, according to the distributed file management system of this invention, since creation of a distributed file is performed in consideration of the load of each server computer, a load distribution comes be made appropriately.

[0063] Next, the case where distributed file reference / updating demand is published to the server computer A105 from the client computer 1 (108-1) in the client computer group A108 is explained.

[0064] First, reference/updating demand to the distributed file A published from the client computer 1 (108-1) is received by the distributed file management section 112 through a network interface 113 in the server computer A105.
[0065] Drawing 7 is a flow chart which shows the algorithm of the distributed file management section at the time of receiving reference/updating demand of a distributed file of operation. Hereafter, detailed operation of the distributed file management section 112 is explained using drawing 7 . Moreover, in the following, concrete operation which made the example processing of reference/updating demand to the distributed file A is also explained.
[0066] First, the distributed file management section 112 is based on reference/updating demand of the distributed file from the client computer 1 (108-1), from the distributed file control table 501 and the partial file control table 601, specifies the partial file referred to / updated, and asks for the address of the partial file (Step 701).
[0067] Here, as for the distributed file management section 112, in reference/updating demand to the distributed file A from the client computer 1 (108-1), based on the distributed file control table 501, it turns out that the distributed file A is constituted by the partial file A1 (126a), the partial file A2 (126c), and the partial file A3 (126d). It is based on the partial file control table 601. moreover, the address of the partial file A1 (126a) It is "file://siteA/serverA/DiskID1/ (storage identifier DiskID1 of the server computer A105 of the computer site A102)." The address of the partial file A2 (126c) is "file://siteC/serverC/DiskID2/(storage identifier DiskID2 of the server computer C107 of the computer site C104)." It turns out that the address of the partial file A3 (126d) is "file://siteC/serverC/DiskID2/(storage DiskID2 of the server C107 of the computer site C104)."
[0068] The distributed file management section 112 judges whether whether all the partial files that perform reference/updating exist in the storage 115 of the server computer A105 of self, a part, or all partial files exist in other server computers from the address of the partial file obtained at Step 701 (Step 702).
[0069] Here, in the case of the distributed file A, it exists in storage 115 and, as for the partial file A1 (126a), it turns out that partial FAIRU A2 (126c) and the partial file A3 (126d) exist in the storage 125 of the server computer C107 of the computer site C104.
[0070] Next, when all partial files do not exist in the storage 115 of the server computer A105 of self (Step 702), based on the address of the partial file obtained at Step 701, existence of a partial file is confirmed to other server computers by which the partial file which performs reference/updating is recorded (Step 703).
[0071] Here, in the case of the distributed file A, existence of the partial file A2 (126c) and the partial file A3 (126d) is checked at the distributed file management section 122 of the server computer C107 of the computer site C104.
[0072] If existence of a partial file is checked at Step 703, the distributed file management section 112 will perform read-out (reference) of the partial file which exists in storage 115 through the partial file management section 111, and the writing (updating) to a partial file based on reference/updating demand from the client computer 1 (108-1), when the partial file which performs reference/updating exists in the storage 115 of the server computer A105 of self. Moreover, when the partial file which performs reference/updating exists in the storage of other server computers, the distributed file management section 112 requires the reference/renewal of an applicable partial file of the server computer holding the partial file which performs reference/updating. It can come, simultaneously the distributed file management section 112 directs to give reference/updating demand to the server computer holding the partial file to which the ******** client computer 1 (108-1) gives reference/updating demand for reference/updating directly (Step 704).
[0073] Here, in the case of the distributed file A, the partial file A1 (126a) exists in the server computer A105 of the computer site A102, and the partial file A2 (126c) and the partial file A3 (126d) exist in the server computer C107 of the computer site C104. As for reference/updating demand to the partial file A1 (126a), the distributed file management section 112 performs reference/update process to storage 115 through the partial file management section 111. On the other hand, reference/updating demand to the partial file A2 (126c) and the partial file A3

(126d) will be directly performed between the client computers 1 (108-1) and the server computers C107 which performed reference/updating demand.
[0074] Moreover, when existence of a partial file is not checked at Step 703, the distributed file management section 112 notifies what the reference/renewal of a distributed file failed in the client computer 1 (108-1) which performed reference/change request of a distributed file (Step 705).
[0075] On the other hand, at Step 702, when all partial files exist in the storage 115 of the server computer A105 of self, the distributed file management section 112 performs read-out (reference) of the partial file which exists in storage 115 through the partial file management section 111, and the writing (updating) to a partial file based on reference/updating demand from the client computer 1 (108-1) (Step 706).
[0076] As mentioned above, according to the gestalt of operation mentioned above, when the demand to a server computer from a client computer is creation of a distributed file, a distributed file is divided into two or more partial files, the server computer which creates each partial file based on the load information on a server computer is determined for every partial file, and creation processing of a distributed file is carried out. Moreover, when the demands from a client computer are the reference/renewal of a distributed file, the server computer by which the partial file which constitutes a distributed file exists is specified, and the partial file distributed and arranged on 1 or two or more server computers is treated as one distributed file from a client computer. Thus, concentration of the load to a specific server computer can be lost in the case of creation / reference / change request of the distributed file from a client computer to a server computer.
[0077] (Gestalt 2 of operation) Drawing 8 is the block diagram showing an example of the gestalt of operation of the 2nd of the distributed file management system in this invention. In this drawing 8 , the same sign is given to the same composition as drawing 1 . The distributed file management system shown in drawing 8 is equipped with the networks 101, such as a Local Area Network which connects mutually two or more computers site A802 equipped with the client computer group which consists of two or more client computers, such as server computers, such as a personal computer and a workstation, and a personal computer, and a workstation, the computer site B803 and the computer site C804, the computer site A802 and the computer site B803, and the computer site C804, and a Wide Area Network.
[0078] Here, the computer site A802 is equipped with two or more server computers (only "the server computer A805" is shown in drawing 8), such as a personal computer and a workstation, and the client computer group A108 which consists of client computer 1-n (108-1 - 108-n), such as a personal computer and a workstation. This computer site A802 has connected two or more server computers (only "the server computer A805" is shown in drawing 8) and client computer groups A108 in the internal networks 131, such as Ethernet, for example, has become the Internet domain.
[0079] Moreover, like the computer site A802, the computer site B803 was equipped with the client computer group B109 which consists of two or more server computers (only "the server computer B806" is shown in drawing 8), and two or more client computers, and the computer site C804 is equipped with the client computer group C110 which consists of two or more server computers (only "the server computer C807" is shown in drawing 8), and two or more client computers. furthermore, these computer sites B803 and the computer site C804 — the computer site A802 — the same — two or more server computers (in drawing 8 , only the "server computer B806" and the "server computer C807" are shown), and the client computer groups B109 and the client computer groups C110 — each — it has connected in the internal network 132 and the internal network 133, for example, has become the Internet domain
[0080] The storage 115, such as a hard disk with which the server computer A805 records the partial file of a distributed file, The network interface 113 for connecting with the internal networks 131, such as Ethernet The partial file management section 111 which controls the writing and read-out to the storage 115 which is recording the partial file, With the state Management Department 814 which supervises the load to storage 115, the remaining capacity of storage 115, and the load to a network interface 113, and holds the information about such

loads and capacity It is constituted by the partial file management section 111, the state Management Department 814, and the distributed file management section 112 connected to the network interface 113.
[0081] This state Management Department 814 has the external state Management Department 811 holding the external load information which notified load information to other server computers, and was notified from other server computers.
[0082] The server computer B806 and the server computer C807 have the same composition as the server computer A805. That is, the server computer B806 is constituted by storage 120, a network interface 118, the partial file management section 116, the state Management Department 819 having the external state Management Department 812, and the distributed file management section 117. Moreover, the server computer C807 is constituted by storage 125, a network interface 123, the partial file management section 121, the state Management Department 824 having the external state Management Department 813, and the distributed file management section 122.
[0083] The difference with the distributed file management system shown in the distributed file management system shown in drawing 8 and drawing 1 here is a point equipped with the external state Management Department 811, 812, and 813 where the state Management Department 814, 819, and 824 which showed drawing 8 holds the external load information which notified load information to other server computers, and was notified from other server computers.
[0084] Drawing 9 shows an example of the external load information table 901 managed at the external state Management Department 811, 812, and 813. In drawing 9 , the external load information table 901 consists of items of the "storage load information" which shows the load information on the storage of the server computer shown in the "server computer address" which shows the address of a server computer, and a server computer address. Moreover, "storage load information" consists of items of the "remaining capacity" which indicates the remaining capacity of storage to be the "load" which shows the "storage identifier" for discriminating storage, and the load of storage.
[0085] The external state Management Department 811, 812, and 813 performs the following operation, in order to notify the external load information from the external load information table 901 to other server computers.
[0086] First, the external state Management Department 811, 812, and 813 acquires the information on the storage load information table 402 managed at the state Management Department 814, 819, and 824 by having the change of state of the information which asks the information shown in the storage load information table 402 to the state Management Department 814, 819, and 824 to periodical or predetermined timing, or is shown in the storage load information table 402 from the state Management Department 814, 819, and 824 notified.
[0087] Next, the external state Management Department 811, 812, and 813 notifies storage load information to each server computer through each network interface 113, 118, and 123. By the server computer which received the notice, through network interfaces 113, 118, and 123, the external state Management Department 811, 812, and 813 receives storage load information, and records this information on each external load information table 901, respectively.
[0088] The case where the creation demand of the distributed file A is published to the server computer A805 about the distributed file management system constituted as mentioned above from the client computer 1 (108-1) in the client computer group A108 is explained as an example.
[0089] First, the creation demand of the distributed file A published from the client computer 1 (108-1) is received by the distributed file management section 112 through the network interface 113 of the internal network 131 and the server computer A805.
[0090] Drawing 10 is a flow chart which shows the algorithm of the distributed file management section when receiving the creation demand of a distributed file of operation. Hereafter, detailed operation of the distributed file management section is explained using drawing 10 . In the gestalt of this operation, processing of Step 302 and Step 303 which are shown in drawing 3 explained with the gestalt of the 1st operation can be unified, and it can process at one step 1002.
[0091] First, the distributed file management section 112 acquires each information from the

load information table 401 which the state Management Department 814 has managed, and the external load information table 901 which the external state Management Department 811 has managed (Step 1001).
[0092] At this state Management Department 114, the load information table 401 as shown in drawing 4 is managed. The load information table 401 is constituted by the storage load information table 402 and the network load information table 403 in drawing 4 .
[0093] This storage load information table 402 consists of items of the "remaining capacity" which indicates the remaining capacity [Mbytes] of each storage section to be the "load" which indicates the load information on each storage section [%] to be the "storage identifier" for discriminating two or more storage sections of the storage 115 connected to the server computer A105. Here, the "load" of each storage section of storage 115 shows what % of the maximum transfer rates of each storage section of storage 115 is used.
[0094] Moreover, the network load information table 403 The data sent out on a network 101 through a network interface 113 [what bandwidth (use communication-band width of face [Mbps]) is used by being sent out towards which computer site (sending-out place site), and] Moreover, the received data are sent from which computer site (sending out agency site), and it is shown whether it has received using the bandwidth (use communication-band width of face [Mbps]) of how much. The item of this "sending out agency site" shows the computer site of the sending-out origin of data, and the item of a "sending-out place site" shows the computer site of the sending-out place of data. That is, in SiteA, SiteB shows the computer site B106 and SiteC shows the computer site C107 for the computer site A105. Here, a transmitting agency site and a transmission place site are named generically, and it is called a network link (only henceforth a "link"). Moreover, the item of "use communication-band width of face" shows the communication-band width of face [Mbps] currently used between the sending out agency site and the sending-out place site.
[0095] Moreover, the external state Management Department 811 has managed the external load information table 901 as shown in drawing 9 .
[0096] Here, when creating the distributed file A, the "load" of the storage section of the storage 115 in which a "storage identifier" is shown by DiskID1 is 20 [%], and the distributed file management section 112 can acquire the information that "remaining capacity" is 10 [Mbytes] from the load information table 401 of the state Management Department 814. The distributed file management section 112 moreover, from the external load information table 901 of the external state Management Department 814 The "load" of the storage section of the storage 120 in which the "storage identifier" of the server computer B806 of the computer site B803 is shown by DiskID1 by 49 [%] The "load" of the storage section of the storage 125 in which "remaining capacity" is 1000 [Mbytes] and the "storage identifier" of the server computer C807 of the computer site C804 is shown by DiskID1 by 30 [%] The information that "remaining capacity" is 3000 [Mbytes] can be acquired.
[0097] Next, the distributed file management section 112 is first based on the storage load information table 402 obtained from the state Management Department 814. "Remaining capacity" out of each storage section of the storage 115 connected to the server computer A805 above a predetermined capacity And a "load" chooses the storage section which fulfills the conditions of being lower than a predetermined threshold, and assigns the partial file which divided the distributed file in order to each storage section which fulfills the conditions concerned. When all partial files are not assigned by storage 115, based on the information on the external load information table 901 that the distributed file management section 112 is obtained from the external state Management Department 811, "remaining capacity" of the storage section is more than a predetermined capacity, and a "load" chooses other server computers with the storage with which the storage section lower than a predetermined threshold exists, and the partial file which is not assigned yet -- being concerned -- others -- the storage section of the storage of a server computer -- order -- assigning -- this allocation -- being concerned -- others -- it notifies to a server computer And it judges whether all partial files assigned the storage section of each storage of a server computer, and have created (Step 1002).

[0098] Here, when creating the distributed file A, the distributed file management section 112 assigns the partial file A1 (126a) to the predetermined storage section of the storage 115 of the server computer A805 based on the storage load information table 401 of the state Management Department 814. Moreover, the distributed file management section 112 assigns the partial file A2 (126c) and the partial file A3 (126d) to each storage section of the storage 125 of the server computer C807 based on the storage load information on the external load information table 901 of the external state Management Department 811.
[0099] Thus, the server computer A805 can determine the server computer which arranges a partial file (storage), taking into consideration other loads and remaining capacity of a server computer without asking other server computers whether creation of a partial file is possible by acquiring the load of other server computers, and the information on remaining capacity from the external state Management Department 811.
[0100] Next, the distributed file management section 112 registers the management information of a distributed file into the distributed file control table 501 as shown in drawing 5 , and the partial file control table 601 as shown in drawing 6 (Step 1003). In drawing 5 , the distributed file control table 501 consists of items of "the partial file identification child list of [for discriminating the partial file which constitutes the "distributed file identification child" and distributed file for discriminating a distributed file]." Moreover, in drawing 6 , the partial file control table 601 consists of items of the "address" which shows the "partial file identification child" for discriminating a partial file, and the address of a partial file. Here, the "partial file identification child" who showed drawing 6 is equivalent to the "partial file identification child" who constitutes the "partial file identification child list" shown by drawing 5 .
[0101] Here, in the case of the distributed file A, in drawing 5 , it means that the distributed file A consists of a partial file A1 (126a), a partial file A2 (126c), and a partial file A3 (126d). Moreover, in drawing 6 , the address of the partial file A1 (126a) is "file://siteA/serverA/DiskID1/(storage identifier DiskID1 of the server computer A105 of the computer site A102)." The address of the partial file A2 (126c) is "file://siteC/serverC/DiskID2/(storage identifier DiskID2 of the server computer C107 of the computer site C104)." The address of the partial file A3 (126d) expresses that it is "file://siteC/serverC/DiskID2/(storage DiskID2 of the server C107 of the computer site C104)."
[0102] Next, the distributed file management section 112 writes the data from the client computer 1 (108-1) in the predetermined storage section of storage 115 through the partial file management section 111, when recording a partial file on the storage section of storage 115. Moreover, in recording a partial file on the storage of other server computers, the distributed file management section 112 requests record of a partial file from the distributed file management section of the server computer which records. It can come, simultaneously it points to the distributed file management section 112 to the client computer 1 (108-1) which performed the creation demand of a distributed file, and directs to transmit immediate data to the server computer which records. By the server computer which received the request from the distributed file management section 112, the data of a partial file are received from the client computer 1 (108-1), and it records on the predetermined storage section of storage. Moreover, the distributed file management section of this server computer registers the information on a partial file to the partial file control table 601 of the partial file management section. Thus, a partial file is created on other server computers (Step 1004).
[0103] In the case of the distributed file A, creation of the partial file A1 (126a) is performed by writing the data from the client computer 1 (108-1) in the predetermined storage section of storage 115. Creation of the partial file A2 (126c) and the partial file A3 (126d) sends predetermined data to the direct server computer C807 from the client computer 1 (108-1), and is performed by writing in the predetermined storage section of the storage 125 of the server computer C807, respectively.
[0104] On the other hand, at Step 1002, when a partial file cannot be created to all the server computer, either, the distributed file management section 112 notifies that creation of a distributed file went wrong to the client computer 1 (108-1) which required distributed file creation (Step 1005).

[0105] As mentioned above, although creation of a distributed file was explained, about the case where reference/updating demand of a distributed file is published from a client computer to a server computer, it is the same as that of the case (drawing 7) of the gestalt of the 1st operation.
[0106] As mentioned above, it sets in the gestalt of operation of the 2nd of this invention. By having the external state Management Department 811, 812, and 813 where the state Management Department 814, 819, and 824 holds the external load information which notified load information to other server computers, and was notified from other server computers The distributed file management sections 112, 117, and 122 can determine the server computer which arranges the partial file of a distributed file based on the load information on other server computers, and can avoid concentration of the load to a specific server computer.
[0107] In addition, in case storage load information is notified to each server computer from the external state Management Department 811, 812, and 813, it is good to use a unicast and multicasting. When multicasting is used especially, storage load information can be notified to all server computers all at once, and the traffic for a notice can be reduced.
[0108] Moreover, the server computer to notify is beforehand divided into two or more groups, and it can also notify to each of the server computer belonging to each group by the unicast, and can also notify by multicasting to each group. Thus, the traffic for a notice can be reduced.
[0109] Furthermore, the server computer to notify can be limited to an adjoining server computer, i.e., the server computer connected directly in the network, and a unicast or multicasting can also notify. Thereby, the traffic for a notice can be reduced.
[0110] (Gestalt 3 of operation) Drawing 11 is the block diagram showing an example of the gestalt of operation of the 3rd of the distributed file management system in this invention. In this drawing 11 , the same sign is given to the same composition as drawing 8 . The distributed file management system shown in drawing 11 is equipped with the networks 101, such as a Local Area Network which connects mutually two or more computers site A1102 equipped with the client computer group which consists of two or more client computers, such as server computers, such as a personal computer and a workstation, and a personal computer, and a workstation, the computer site B1103 and the computer site C1104, the computer site A1102 and the computer site B1103, and the computer site C1104, and a Wide Area Network.
[0111] Here, the computer site A1102 is equipped with two or more server computers (only "the server computer A1105" is shown in drawing 11), such as a personal computer and a workstation, and the client computer group A108 which consists of client computer 1-n (108-1 - 108-n), such as a personal computer and a workstation. This computer site A1102 has connected two or more server computers (only "the server computer A1105" is shown in drawing 11) and client computer groups A108 in the internal networks 131, such as Ethernet, for example, has become the Internet domain.
[0112] Moreover, like the computer site A1102, the computer site B1103 was equipped with the client computer group B109 which consists of two or more server computers (only "the server computer B1106" is shown in drawing 11), and two or more client computers, and the computer site C1104 is equipped with the client computer group C110 which consists of two or more server computers (only "the server computer C1107" is shown in drawing 11), and two or more client computers. furthermore, these computer sites B1103 and the computer site C1104 -- the computer site A1102 -- the same -- two or more server computers (in drawing 11 , only the "server computer B1106" and the "server computer C1107" are shown), and the client computer groups B109 and the client computer groups C110 -- each -- it has connected in the internal network 132 and the internal network 133, for example, has become the Internet domain
[0113] The storage 115, such as a hard disk with which the server computer A1105 records the partial file of a distributed file, The network interface 113 for connecting with the internal networks 131, such as Ethernet The partial file management section 111 which controls the writing and read-out to the storage 115 which is recording the partial file, With the state Management Department 814 which supervises the load to storage 115, the remaining capacity of storage 115, and the load to a network interface 113, and holds the information about such loads and capacity It is constituted by the partial file management section 111, the state

Management Department 814, and the distributed file management section 1112 connected to the network interface 113.
[0114] This state Management Department 814 has the external state Management Department 811 holding the external load information which notified load information to other server computers, and was notified from other server computers.
[0115] Moreover, the distributed file management section 1112 determined the partial file to which it is made to move based on the information on the access information for every partial file, and the load information external load information table 401 and 901, and is equipped with the distributed file move section 1131 which moves a partial file to other server computers.
[0116] The server computer B1106 and the server computer C1107 have the same composition as the server computer A1105. That is, the server computer B1106 is constituted by storage 120, a network interface 118, the partial file management section 116, the state Management Department 819 having the external state Management Department 812, and the distributed file management section 1117 equipped with the distributed file move section 1132. Moreover, the server computer C1107 is constituted by storage 125, a network interface 123, the partial file management section 121, the state Management Department 824 having the external state Management Department 813, and the distributed file management section 1122 equipped with the distributed file move section 1133.
[0117] The difference with the distributed file management system shown in the distributed file management system shown in drawing 11 and drawing 8 here is a point equipped with the distributed file move sections 1131, 1132, and 1133 which the distributed file-management sections 1112, 1117, and 1122 shown in drawing 11 determine the partial file to which it is made to move, and make move a partial file to other server computers from the information on the access information for every partial file, and the load information external load information table 401 and 901.
[0118] Drawing 12 shows an example of the access information table 1201 for every partial file managed at the state Management Department 814. In drawing 12 , this access information table 1201 consists of a "partial file identification child" for discriminating a partial file, and an item of "the access information around unit time." Moreover, "the access information around unit time" consists of items of "the number of times of access" which indicates the number of times of access to a partial file to be the "accessing agency site identifier" which is the information on a site that the client computer which has accessed the partial file exists. It is continued by updating this access information table 1201 the state Management Department 814 for every unit time.
[0119] Drawing 13 shows an example of the partial file control table 1301 managed in the distributed file management section 1112. In drawing 13 , the partial file control table 1301 consists of items of the "original address" which shows the "address" which shows the "partial file identification child" for discriminating a partial file, and the address of a partial file, and the address where the partial file was created first. In drawing 13 , in the stage where the partial file was created, although the information which an "address" and an "original address" show is the same, the information on an "address" changes according to a partial file moving to other server computers. The partial file control table 1301 shown by drawing 13 is what added the item of an "original address" to the partial file control table 601 shown by drawing 6 .
[0120] In the distributed file management system constituted as mentioned above, as the distributed file A, the distributed file B, and the distributed file C show by ****, after they are created by the server computer A1105, the processing which moves the partial file of each distributed file is explained in detail.
[0121] Drawing 14 shows an example of the contents of the partial file control table 1301 of the distributed file A created by the server computer A1105, the distributed file B, and the distributed file C. In drawing 14 , drawing 14 (A) shows the partial file control table 1401 of the server computer A1105, (B) shows the partial file control table 1402 of the server computer B1106, and (C) shows the partial file control table 1403 of the server computer C1107. The address of each partial file where a partial file identification child is shown by A1, A2, A3, B1, C1, and C2, and the original address are shown in the partial file control table 1401 of drawing 14 (A).

The address of each partial file where a partial file identification child is shown by C1 and C2, and the original address are shown in the partial file control table 1402. The address of each partial file where a partial file identification child is shown by A2 and A3, and the original address are shown in the partial file control table 1403. Here, in drawing 14 , the state before movement of each partial file is expressed. For this reason, in all partial files, the address and original address are in agreement.
[0122] The algorithm of the distributed file move section 1131 of the server computer A1105 in the case of movement of the partial file in the state which showed in drawing 14 of operation is explained.
[0123] Drawing 15 shows the algorithm of the distributed file move section 1131 of operation. First, the distributed file move section 1131 supervises the information on the load information table 401 (drawing 4) which the state Management Department 814 has managed at intervals of fixed time (Step 1501).
[0124] The distributed file move section 1131 will look for the "partial file identification child" of the partial file included in this detected storage with reference to the partial file control table 1301, if it detects that the "load" of a certain storage exceeded the predetermined threshold (for example, it is values, such as 80 etc.%, and the structure of a system etc. determines this value arbitrarily) set up beforehand (Step 1501). Discovered "the access information per unit time" of a "partial file identification child" is acquired from the access information table 1201. "the number of times of access" of "the access information per unit time" acquired here — ** "— as compared with every partial file identification child", the "partial file identification child" who is biggest "number of times of access" is chosen (Step 1502) That is, a move dimension partial file is chosen. For example, suppose that the partial file A1 (126a) was chosen as a move dimension partial file here.
[0125] Next, the distributed file move section 1131 chooses the server computer in which "remaining capacity" appears enough and a "load" has low storage from a predetermined value based on the external load information table 901 (drawing 9). And the distributed file move section 1131 checks whether a partial file can move to the selected server computer, and determines the server computer which can move (Step 1502). That is, a movement place server computer is chosen. For example, suppose that the storage section of the storage 125 shown by the storage identifier DiskID2 of the server computer C1107 was chosen here.
[0126] Next, a partial file is moved based on the information acquired by selection of this move dimension partial file, and selection of a movement place server computer (Step 1503).
[0127] In an above-mentioned example, by Step 1502, since the server computer C1107 is chosen as a move dimension partial file as the partial file A1 (126a) and a movement place server computer, the distributed file move section 1131 of the server computer A1105 of a moved material reads the partial file A1 (126a) from storage 115 through the partial file management section 111. This read partial file A1 (126a) is sent out through a network interface 113 and the internal network 131 in a network 101 with the information about the "original address" (drawing 13) of the partial file A1 (126a).
[0128] On the other hand, in the server computer C1107 of a movement place, the distributed file move section 1133 receives the information on the partial file A1 (126a) sent out from the server computer A1105 of a moved material, and its "original address" through the interior network 133 of network 101 shell, and a network interface 123. The partial file management section 121 writes this partial file A1 (126a) that received in storage 125. Moreover, the "original address" of the partial file A1 (126a) is registered into the partial file control table (drawing 14 (C)) of the partial file management section 121.
[0129] Then, the server computer C1107 of a movement place notifies that movement of the partial file A1 (126a) was completed to the server computer (the server computer A1105 with the server computer A1105 same in the case of this example, i.e., a moved material and original) shown in the server computer A1105 and an "original address" (drawing 13) of a moved material. By the server computer shown in the server computer A1105 and an "original address" of a moved material, the information on the partial file A1 (126a) registered into the partial file control table is rewritten.

[0130] Drawing 16 shows the state of the partial file control tables 1401, 1402, and 1403 shown in drawing 14 after the partial file A1 (126a) moves like an above-mentioned example. In drawing 16 , drawing 16 (A) shows the partial file control table 1601 of the server computer A1105, (B) shows the partial file control table 1602 of the server computer B1106, and (C) shows the partial file control table 1603 of the server computer C1107. That is, each partial file control tables 1601, 1602, and 1603 of drawing 16 (A) - (C) correspond to each partial file control tables 1401, 1402, and 1403 of drawing 14 (A) - (C), respectively. Here, the "address" of each partial file where a "partial file identification child" is shown by A1, A2, A3, B1, C1, and C2, and the "original address" are shown in the partial file control table 1601. The "address" of each partial file where a "partial file identification child" is shown by C1 and C2, and the "original address" are shown in the partial file control table 1602. The "address" of each partial file where a "partial file identification child" is shown by A1, A2, and A3, and the "original address" are shown in the partial file control table 1603. Here, the difference in the state of the partial file control tables 1401, 1402, and 1403 shown in the state and drawing 14 of the partial file control tables 1601, 1602, and 1603 shown in drawing 16 depends the partial file A1 (126a) on having made it move to the server computer C1107 from the server computer A1105. Namely, the difference between drawing 16 and drawing 14 is set to the partial file control table 1401 of drawing 14 (A). The information registered as the "address" of the partial file A1 (126a) is "file://siteA/serverA/DisilD1/" In the partial file control table 1601 of drawing 16 (A) The "addresses" of the partial file A1 (126a) is "file://siteC/serverC/DiskID2/", the point registered, and the point that the item of the partial file A1 is added in the partial file control table 1603 of drawing 16 (C).

[0131] Drawing 17 shows a partial file control table when the distributed file move section 1132 of the server computer B1106 moves the partial file C1 (126e) to the server computer C1107 and the distributed file move section 1133 of the server computer C1107 moves the partial file A1 (126a) to the server computer B1106 like the processing mentioned above further from the state which showed in this drawing 16 .

[0132] In drawing 17 , drawing 17 (A) shows the partial file control table 1701 of the server computer A1105, (B) shows the partial file control table 1702 of the server computer B1106, and (C) shows the partial file control table 1703 of the server computer C1107. The "address" of each partial file where a "partial file identification child" is shown by A1, A2, A3, B1, C1, and C2, and the "original address" are shown in the partial file control table 1701. The "address" of each partial file where a "partial file identification child" is shown by C1, C2, and A1, and the "original address" are shown in the partial file control table 1702. Moreover, the "address" of each partial file where a "partial file identification child" is shown by A2, A3, and C1, and the "original address" are shown in the partial file control table 1703.

[0133] Here, the difference in the state of the partial file control tables 1601, 1602, and 1603 shown in the state and drawing 16 of the partial file control tables 1701, 1702, and 1703 shown in drawing 17 depends having moved the partial file A1 (126a) to the server computer B1106 from the server computer C1107, and the partial file C1 (126e) for having made it move to the server computer C1107 from the server computer B1106.

[0134] That is, corresponding to movement of the partial file A1 (126a), the item of the partial file A1 (126a) is added to the partial file control table 1702. Moreover, in the partial file control table 1703, the item (refer to drawing 16) of the partial file A1 (126a) is deleted. Furthermore, with reference to the "original address" of the partial file A1 (126a), the server computer B1106 told the server computer A1105 about movement, and has changed into "file://siteB/serverB/DiskID2/" the "address" of the partial file A1 (126a) registered into the partial file control table 1701 by this notice in the server computer A1105 shown in an "original address."

[0135] Moreover, corresponding to movement of the partial file C1 (126e), the "address" of the partial file C1 (126e) registered into the partial file control table 1702 is changed into "file://siteC/serverC/DiskID3/" from "file://siteB/serverB/DisilD3/" (drawing 16 (B)). Moreover, in the partial file control table 1703, the item of the partial file C1 (126e) is added.

[0136] Next, in the state which shows in drawing 17 , in case the client computer 1 (108-1) refers to the distributed file C, operation in case the content of reference is included in the partial file C1 (126e) is explained.

[0137] (1) The client computer 1 (108-1) requires reference of the distributed file C from the server computer A1105 which created the distributed file C. By the server computer A1105, it investigates which partial file is referred to with reference to the distributed file control table 1701 among the partial files C1 and C2 which constitute the distributed file C. Here, it considers as the partial file C1 (126e). Since the "address" of the partial file C1 (126e) is "file://siteB/serverB/DiskID3/", the server computer A1105 checks whether the partial file C1 (126e) exists to the server computer B1106.

[0138] (2) The server computer B1106 investigates the distributed file control table 1702, and investigates the "address" of the partial file C1 (126e). Since the "address" of the partial file C1 (126e) is "file://siteC/serverC/DiskID3/", the server computer B1106 checks whether the partial file C1 (126e) exists to the server computer C1107.

[0139] (3) The server computer C1107 investigates the distributed file control table 1703, and investigates the "address" of the partial file C1 (126e). Since the "address" of the partial file C1 (126e) is "file://siteC/serverC/DiskID3/", it turns out that the partial file C1 (126e) exists in the server computer C1107.

[0140] (4) Notify that the server computer C1107 exists in the server computer B1106, and the partial file C1 (126e) exists in "file://siteC/serverC/DiskID3/."

[0141] (5) In response to this notice, the server computer B1106 notifies that the partial file C1 (126e) exists in the server computer A1105 at "file://siteC/serverC/DiskID3/."

[0142] (6) The server computer A1105 requires reference of the partial file C1 (126e) of the server computer C1107. Simultaneously with this demand, it directs to give the reference demand of the partial file C1 (126e) to the server computer C1107 directly to the client computer 1 (108-1) which required reference. Moreover, by the server computer A1105, the "address" of the partial file C1 (126e) is rewritten to "file://siteC/serverC/DiskID3/."

[0143] As mentioned above, with the gestalt of this operation, the distributed file management sections 1112, 1117, and 1122 determine the partial file to which it is made to move based on each information on the access information load information table [external load information] 1201, 401, and 901 for every partial file. Moreover, concentration of the load to the storage of a specific server computer is avoidable by moving a partial file to other server computers by having the distributed file move sections 1131, 1132, and 1133 which move a partial file to other server computers.

[0144] In addition, with the gestalt of the 3rd operation mentioned above, it sets to Step 1501 of the algorithm (drawing 15) of the distributed file move section 1131 of operation. Instead of detecting that the "load" of each storage section of storage exceeded the predetermined value You may make it detect that "remaining capacity" of each storage section of storage was less than values (however, this value is determined according to equipment or the structure of a system), such as a predetermined value [Mbytes], 10 [for example,] etc. The imbalance of the capacity of each storage section of storage is avoidable with this.

[0145] Moreover, in the above-mentioned step 1501, "use communication-band width of face" can detect the link beyond the predetermined value (however, this value is determined according to equipment or the structure of a system), for example, the value of 80 [%] of usable communication-band width of face, from the "load information" on a network 101 instead of detecting that the "load" of each storage section of storage exceeded the predetermined value. Moreover, in Step 1502, concentration of the load of a network is avoidable by choosing from the access information table 1201 the computer site which is raising the partial file which is raising the load of a network 101, and the load of a network. For example, when the "use communication-band width of face" (drawing 4) of the link of the computer site A1102 (sending out agency site) and the computer site B1103 (sending-out place site) exceeds a predetermined value, it exists in the server computer A1105, and the partial file used as the cause which raises a network load is moved to the server computer B1103. Thereby, the "use communication-band width of face" between the computer site A1102 and the computer site B1103 can be decreased.

[0146] Moreover, with the gestalt of the 3rd operation of a ****, although it checks whether the partial file of the server computer of a movement place is movable in Step 1502 and the partial file is moved in Step 1503, check processing of Step 1502 can be omitted by moving a partial file, without whether movement of a partial file at Step 1502 is possible in advance, and checking. When movement of a partial file is unacceptable by the server computer side of the movement place of a partial file at this time, the server computer of a movement place looks for the movement place for moving a partial file further, and should just move this partial file.
[0147] moreover -- although it is moving to the server computer of a movement place from the server computer of partial file move-origin in the above-mentioned step 1503 -- the move processing -- in addition, other partial files which can move to the server computer of a moved material out of the partial file in the server computer of a movement place -- choosing -- being concerned -- others -- you may make it move a partial file to the server computer of a moved material This can protect that a partial file concentrates on one server computer, and the load to a file access can be mitigated more.
[0148] Moreover, in the above-mentioned step 1502, in case the server computer of the movement place of a partial file is chosen, it is good to choose the server computer in which a server computer list is beforehand set, has the remaining capacity of enough of each storage section of storage, and a load has low storage from a predetermined value out of the server computer under list. By this, the time spent on selection of the server computer of the movement place of a partial file can be shortened.
[0149] (Gestalt 4 of operation) Drawing 18 is a flow chart which shows other algorithms of the distributed file move sections 1131, 1132, and 1133 of distributed file management system of operation shown in drawing 11 .
[0150] In drawing 18 , the distributed file move sections 1131, 1132, and 1133 supervise the communication cost to each partial file at the predetermined intervals first (Step 1801). Here, as communication cost, it can consider as the communication time between the client computer which is referring to the partial file, and the server computer holding the partial file, for example. In drawing 11 , communication cost of the client computer 1 (108-1) and the partial file A2 (126c) is taken as the communication time between the client computer 1 (108-1) which is referring to the partial file A2 (126c), and the server computer C1107 holding the partial file A2 (126c).
[0151] the distributed file move sections 1131, 1132, and 1133 exceeded the value predetermined in the communication cost to a partial file, for example, 1 etc. second etc., here (however, this value is determined according to equipment or the structure of a system) -- detecting (Step 1801) -- communication cost chooses as a partial file of partial file beyond predetermined value move-origin (Step 1802) Moreover, when two or more client computers have accessed to the partial file whose communication cost of this exceeded the predetermined value, it asks for the communication cost to each access, and these are added and it asks for sum total communication cost.
[0152] In case the server computer of a movement place is chosen, based on the external load information table 901, there is "remaining capacity" of enough of each storage section of storage, and the "load" to them chooses a server computer with low storage from a predetermined value. And as a result of transmitting above-mentioned sum total communication cost and moving a partial file to the selected server computer, it asks in order how communication cost changes, and the server computer which becomes the minimum communication cost is chosen (Step 1802). Or the distributed file move sections 1131, 1132, and 1133 have an initial entry between sites, expect communication cost from the initial entry, and you may make it choose the server computer which becomes the minimum communication cost (Step 1802).
[0153] Drawing 19 is drawing showing an example of an initial-entry table. In drawing 19 , the initial-entry table 1901 has the item of "communication time" to show the communication cost from the "sending out agency site" which sends out a partial file, the "sending-out place site" where a partial file is sent out, and a sending out agency site to a sending-out place site. The "communication time" between a server computer and a client computer can be obtained from

this initial-entry table 1901 by to which site the server computer holding a partial file belongs to which site, and the client computer which refers to a partial file belongs. Based on this "communication time" and the sum total communication cost mentioned above, the server computer by which "communication time" serves as the minimum after movement of a partial file is chosen as a movement place of a partial file (Step 1802). When two or more client computers have accessed the partial file whose communication cost exceeded the predetermined value here, it is good to choose the server computer by which the "communication time" after movement of a partial file becomes the minimum communication cost.
[0154] For example, when the communication cost (henceforth "cost A2") of the client computer 1 (108-1) and the partial file A2 (126c) exceeds a predetermined value and the partial file A2 (126c) is moved to the server computer A1105, it asks the server computer A1105 what communication cost becomes, or asks for communication cost from the initial-entry table 1901. The result will make the server computer A1105 the candidate of a movement place server computer, if less than cost A2. This processing is performed also to other server computers, and the server computer by which communication cost becomes the minimum is looked for (Step 1802).
[0155] Finally, a partial file is moved based on the information acquired by selection of this move dimension partial file, and selection (Step 1802) of a movement place server computer (Step 1803).
[0156] With the gestalt of the 4th operation, the distributed file move sections 1131, 1132, and 1133 As mentioned above, each information on the load information external load information table [access information] 401, 901, and 1201, It is based on the initial entry between the server computer obtained from the initial-entry table 1901, and a client computer. It asks for the communication cost between the server computer by which the partial file under processing exists, and the client computer of the demand origin of processing. Since the partial file was moved to other server computers which become small [communication cost] when communication cost exceeded a predetermined value In addition to the effect which was mentioned above and which is acquired with the gestalt of the 3rd operation, the average of the access time to the partial file from a client computer can be shortened.
[0157] In addition, although communication time is mentioned as the example with the gestalt of the 4th operation of a **** as communication cost, it can also be made "delay" of communication time, "fluctuation (range of fluctuation) etc.", etc.
[0158] Moreover, although the partial file is moved with the gestalt of the 4th operation of a **** so that sum total communication cost may be made into the minimum when two or more client computers have accessed the same partial file, you may make it move a partial file so that average communication cost may be made into the minimum.
[0159] (Gestalt 5 of operation) Drawing 20 is the block diagram showing an example of the gestalt of operation of the 5th of the distributed file management system in this invention. In this drawing 20 , the same sign is given to the same composition as drawing 8 . The distributed file management system shown in drawing 20 is equipped with the networks 101, such as a Local Area Network which connects mutually two or more computers site A2002 equipped with the client computer group which consists of two or more client computers, such as server computers, such as a personal computer and a workstation, and a personal computer, and a workstation, the computer site B2003 and the computer site C2004, the computer site A2002 and the computer site B2003, and the computer site C2004, and a Wide Area Network.
[0160] Here, the computer site A2002 is equipped with two or more server computers (only "the server computer A2005" is shown in drawing 20), such as a personal computer and a workstation, and the client computer group A108 which consists of client computer 1-n (108-1 - 108-n), such as a personal computer and a workstation. This computer site A2002 has connected two or more server computers (only "the server computer A2005" is shown in drawing 20) and client computer groups A108 in the internal networks 131, such as Ethernet, for example, has become the Internet domain.
[0161] Moreover, like the computer site A2002, the computer site B2003 was equipped with the

client computer group B109 which consists of two or more server computers (only "the server computer B2006" is shown in drawing 20), and two or more client computers, and the computer site C2004 is equipped with the client computer group C110 which consists of two or more server computers (only "the server computer C2007" is shown in drawing 20), and two or more client computers. furthermore. these computer sites B2003 and the computer site C2004 — the computer site A2002 -- the same -- two or more server computers (in drawing 20 , only the "server computer B2006" and the "server computer C2007" are shown), and the client computer groups B109 and the client computer groups C110 — each — it has connected in the internal network 132 and the internal network 133, for example, has become the Internet domain

[0162] The storage 115, such as a hard disk with which the server computer A2005 records the partial file of a distributed file, The network interface 113 for connecting with the internal networks 131, such as Ethernet The partial file management section 111 which controls the writing and read-out to the storage 115 which is recording the partial file, With the state Management Department 814 which supervises the load to storage 115, the remaining capacity of storage 115, and the load to a network interface 113, and holds the information about such loads and capacity It is constituted by the partial file management section 111, the state Management Department 814, and the distributed file management section 2012 connected to the network interface 113.

[0163] This state Management Department 814 has the external state Management Department 811 holding the external load information which notified load information to other server computers, and was notified from other server computers.

[0164] Moreover, the distributed file management section 2012 determined the partial file to copy based on each information for every partial file obtained from the access information load information table [external load information] 1201 (drawing 12), 401 (drawing 4), and 901 (drawing 9), and is equipped with the distributed file copy section 2001 which copies the partial file concerned to other server computers.

[0165] The server computer B2006 and the server computer C2007 have the same composition as the server computer A2005. That is, the server computer B2006 is constituted by storage 120, a network interface 118, the partial file management section 116, the state Management Department 819 having the external state Management Department 812, and the distributed file management section 2017 equipped with the distributed file copy section 2032. Moreover, the server computer C2007 is constituted by storage 125, a network interface 123, the partial file management section 121, the state Management Department 824 having the external state Management Department 813, and the distributed file management section 2022 equipped with the distributed file copy section 2033.

[0166] The differences with the distributed file management system shown here in the distributed file management system shown in drawing 20 and drawing 8 are the distributed file copy sections 2031 and 2032 which determine the partial file which the distributed file-management sections 2012, 2017, and 2022 shown in drawing 20 copy based on each information for every partial file obtained from the access information load information table [external load information] 1201, 401, and 901, and copy the partial file concerned to other server computers, and a point equipped with 2033 **.

[0167] Operation of the distributed file management system constituted as mentioned above is explained in detail taking the case of the case where a partial file is copied, after being created, as the distributed file A, the distributed file B, and the distributed file C show drawing 20 by the server computer A2005.

[0168] Drawing 21 is a flow chart which shows the algorithm of the distributed file copy section 2031 of the server computer A2005 of operation. In drawing 21 , the distributed file copy section 2031 supervises first the load information table 401 (drawing 4) which the state Management Department 814 has managed by the predetermined time interval (Step 2101).

[0169] as for the distributed file copy section 2031, the "load" of the arbitrary storage sections of storage 115 exceeded values, such as a predetermined value [%], 80 [for example,] etc., — detecting (Step 2101) -- the partial file included in the storage section of the detected storage 115 is discovered with reference to the partial file control table 1301 (drawing 13) And the

access information on the discovered partial file is acquired from the access information table 1201. "The number of times of access" of the acquired access information is compared, and the partial file which is biggest "number of times of access" is chosen as a copy dimension partial file. Here, suppose that the partial file A1 (126a) was chosen. Next, based on the external load information table 901 (drawing 9), there is "remaining capacity" of enough of the storage section of storage, and the server computer in which a "load" has low storage from a predetermined value is chosen. And it checks whether a partial file can be copied to the selected server computer, and the server computer which can be copied is chosen as a copy place server computer (Step 2102).

[0170] Here, suppose that the storage section (storage identifier : DiskID2) of the storage 125 of the server computer C2007 was chosen.

[0171] Based on the information acquired by selection of this copy dimension partial file, and selection of a copy place server computer, a partial file is copied (Step 2103) and surveillance processing of Step 2101 is continued again.

[0172] Since the server computer C2007 was chosen as a copy dimension partial file at Step 2102 as the partial file A1 (126a) and a copy place server computer in the case of the above-mentioned example, here The distributed file copy section 2031 of the server computer A2005 of a copied material Through the partial file management section 111, the partial file A1 (126a) is read from storage 115, and this partial file A1 (126a) is sent out to a network 101 through a network interface 113. Moreover, the information about the "original address" (drawing 13) of the partial file A1 (126a) is also sent out simultaneously.

[0173] On the other hand, by the server computer C2007 of a copy place, the distributed file copy section 2033 receives the partial file A1 (126a) sent out from the server computer A2005 of a copied material through a network interface 123. And it writes in the predetermined storage section of storage 125 through the partial file management section 121. Moreover, the "original address" of the partial file A1 (126a) is received, and it registers with the partial file control table 1403. Then, the server computer C2007 of a copy place notifies that the copy of the partial file A1 (126a) was completed to the server computer (in the case of this example, an "original address" is the storage section of the storage 115 of the server computer A2005) shown in the server computer A2005 and an "original address" of a copied material. By the server computer (both server computer A2005) shown in the server computer and an "original address" of a copied material, the information on the partial file A1 (126a) of the partial file control table 1401 is rewritten.

[0174] Drawing 22 is drawing showing the partial file control table of the server computer after copy processing. The partial file control tables 1401, 1402, and 1403 shown in drawing 14 change to the state of the partial file control tables 2201, 2202, and 2203 shown in drawing 22 as a result of the copy of the above-mentioned partial file A1 (126a). That is, drawing 22 (A) shows the partial file control table 2201 of the server computer A2005, (B) shows the partial file control table 2202 of the server computer B2006, and (C) shows the partial file control table 2203 of the server computer C2007. Moreover, the "address" of each partial file where a "partial file identification child" is shown by A1, A2, A3, B1, C1, and C2, and the "original address" are shown in the partial file control table 2201. Moreover, the "address" of each partial file where a "partial file identification child" is shown by C1 and C2, and the "original address" are shown in the partial file control table 2002. Moreover, the "address" of each partial file where a "partial file identification child" is shown by A1, A2, and A3, and the "original address" are shown in the partial file control table 2203. The difference between the state of a partial file control table shown in drawing 14 and the state of a partial file control table shown in drawing 22 is a difference by having copied the partial file A1 (126a) to the server computer C2007 from the server computer A2005. Namely, it sets to the partial file control table 1401 of drawing 14 (A). As opposed to the "address" of the partial file A1 (126a) being "file://siteA/serverA/DisilD1/" In the partial file control table 2201 of drawing 22 (A) The point that "address" ** is "file://siteA/serverA/DiskID1/" and "file://siteC/serverC/DiskID2/(address of a copy)" is different. [of the partial file A1 (126a)] Furthermore, in the partial file control table 2103 of drawing 22 (C), the item of the partial file A1 (126a) is added.

[0175] Moreover, from the state of drawing 22 , the distributed file copy section 2032 of the server computer B2006 can copy the partial file C1 (126e) to the server computer C2007, and the distributed file copy section 2033 of the server computer C2007 can also copy the partial file A1 (126a) to the server computer B2006.
[0176] Drawing 23 is drawing showing the partial file control table in the state where the partial file was copied further, from the state of drawing 22 . Drawing 23 (A) shows the partial file control table 2301 of the server computer A2005, (B) shows the partial file control table 2302 of the server computer B2006, and (C) shows the partial file control table 2303 of the server computer C2007. The "address" of each partial file of A1, A2, A3, B1, C1, and C2 and the "original address" are shown for the "partial file identification child" in the partial file control table 2301 of drawing 23 (A). The "address" of each partial file of C1, C2, and A1 and the "original address" are shown for the "partial file identification child" in the partial file control table 2302 of drawing 23 (B). Moreover, the "address" of each partial file of A1, A2, A3, and C1 and the "original address" are shown for the "partial file identification child" in the partial file control table 2303 of drawing 23 (C). The difference between the state of the partial file control table of drawing 22 and the state of the partial file control table of drawing 23 is because the partial file C1 (126e) was copied [having copied the partial file A1 (126a) to the server computer B2006 from the server computer C2007, and] to the server computer C2007 from the server computer B2006.
[0177] That is, corresponding to the copy of the partial file A1 (126a), the item of the partial file A1 (126a) is added in the partial file control table 2302. Moreover, the server computer A2005 of an "original address" has added "file://siteB/serverB/DiskID2/" to the "address" of the partial file A1 (126a) in the partial file control table 2301 because the server computer B2006 tells the server computer A2005 about a copy with reference to the "original address" of the partial file A1 (126a). Moreover, corresponding to the copy of the partial file C1 (126e), the item of the partial file C1 (126e) is added in the partial file control table 2303. Furthermore, in the partial file control table 2302, the "address" of the partial file C1 (126e) is "file://siteB/serverB/DiskID3/" and "file://siteC/serverC/DiskID3/(address of a copy)."
[0178] In the state which shows in drawing 23 , in case the client computer 1 (108-1) refers to the distributed file C, operation in case the content of reference is included in the partial file C1 (126e) is explained.
[0179] (1) The client computer 1 (108-1) requires reference of the distributed file C from the server computer A2005 which created the distributed file C. By the server computer A2005, it investigates which partial file is referred to with reference to the distributed file control table 2301 among the partial files C1 and C2 which constitute the distributed file C, and recognizes that it is reference of the partial file C1 (126e). Since the "address" of the partial file C1 (126e) is "file://siteB/serverB/DiskID3/" in the distributed file control table 2301, the server computer A2005 checks whether the partial file C1 (126e) exists to the server computer B2006.
[0180] (2) The server computer B2006 investigates the distributed file control table 2302, and investigates the address of the partial file C1 (126e). Since the "addresses" of the partial file C1 (126e) is "file://siteB/serverB/DiskID3/" and "file://siteC/serverC/DiskID3/" in the distributed file control table 2302, the server computer B2006 chooses the low server computer of a load from the load information table 401 and the external load information table 901 among the server computer B2006 and the server computer C2007. Here, when the server computer C2007 is chosen, the server computer B2006 checks whether the partial file C1 (126e) exists to the server computer C2007.
[0181] (3) The server computer C2007 investigates the distributed file control table 2303, and checks the "address" of the partial file C1 (126e). Since the "address" of the partial file C1 (126e) is "file://siteC/serverC/DiskID3/" in the distributed file control table 2303, it turns out that the partial file C1 (126e) exists in the server computer C2007.
[0182] (4) The server computer C2007 notifies that the partial file C1 (126e) exists at "file://siteC/serverC/DiskID3/" to the server computer B2006.
[0183] (5) The server computer B2006 notifies that the partial file C1 (126e) exists at "file://siteC/serverC/DiskID3/" to the server computer A2005.

[0184] (6) The server computer A2005 requires reference of the partial file C1 (126e) of the server computer C2007. Simultaneously with this demand, it is directed that the client computer 1 (108-1) gives the reference demand of the partial file C1 (126e) to the server computer C2007 directly to the client computer 1 (108-1) which required reference.
[0185] With the gestalt of this operation, as mentioned above, the distributed file management sections 112, 117, and 122 It is based on each information for every partial file obtained from the access information load information table [external load information] 1201, 401, and 901. When the partial file to copy is determined and the distributed file copy sections 2031, 2032, and 2033 copy a partial file to other server computers, concentration of the load to the storage of a specific server computer is avoidable.
[0186] In addition, with the gestalt of the 5th operation, you may decide to replace with detecting the thing which were mentioned above and for which the "load" of each storage section of storage exceeded the predetermined value, and to detect the link "whose use communication-band width of face" of the network load information table 403 exceeded the predetermined value in Step 2101 of the algorithm (drawing 21) of the distributed file copy section 2031 of operation. Moreover, you may make it choose from the access information table 1201 the partial file which is raising the network load, and the computer site which is raising the network load in Step 2102. Concentration of a network load is avoidable with this. For example, when the "use communication-band width of face" of the link of the computer site A2002 (sending out agency site) and the computer site B2003 (sending-out place site) exceeds a predetermined value, it exists in the server computer A2005, and the partial file used as the cause which raises a network load is copied to the server computer B2003. Thereby, the "use communication-band width of face" between the computer site A2002 and the computer site B2003 decreases.
[0187] Drawing 24 is a flow chart which shows other algorithms of the distributed file copy section 2031 of the server computer A2005 of operation. In drawing 24 , the distributed file copy section 2031 supervises the communication cost to a partial file at the predetermined intervals first (Step 2401).
[0188] Here, it can consider as the communication time between the client computer which is referring to for example, the partial file, and the server computer holding the partial file at communication cost. For example, what is necessary is just to make it into the communication time between the client computer 1 (108-1) which is referring to the partial file A2 (126c), and the server computer C2007 holding the partial file A2 (126c) in the case of the communication cost of the client computer 1 (108-1) and the partial file A2 (126c).
[0189] Next, the distributed file copy section 2031 chooses the partial file to which this communication cost exceeded the predetermined value as a copy dimension partial file, when the communication cost to a partial file detects having exceeded the predetermined value (Step 2401). When two or more client computers have accessed the partial file whose communication cost exceeded the predetermined value, it asks for each communication cost for every access, and these are added to it and it is asked for sum total communication cost. When choosing the server computer of a copy place, as a result of there having been "remaining capacity" of enough of the storage section of storage, and choosing the server computer in which a "load" has low storage, transmitting sum total communication cost to the selected server computer and copying a partial file on the other hand based on the external load information table 901, it is asked in order how communication cost changes. And the server computer which becomes the minimum communication cost is chosen as a copy place server computer. Or as an initial entry between sites (between a server computer and client computers), the distributed file copy sections 2031, 2032, and 2033 have the initial-entry table 1901 shown in drawing 19 , expect communication cost (communication time) from the information, and you may make it choose the server computer which becomes the minimum communication cost. The "communication time" between a server computer and a client computer can be obtained using the information on the initial-entry table 1901 of drawing 19 , and the information on to which site a server computer belongs to which site and a client computer belongs. And it is good to choose the server computer by which the "communication time" serves as the minimum as a copy place of a

partial file. When two or more client computers have accessed the partial file whose communication cost exceeded the predetermined value, the server computer which becomes the minimum sum total communication cost is chosen as a copy place server computer (Step 2402).
[0190] For example, when the communication cost (cost A2) of the client computer 1 (108-1) and the partial file A2 exceeds a predetermined value and the partial file A2 is copied to the server computer A105, it is asked to the server computer A105 what communication cost becomes. Or it asks for cost from an initial entry 1801. The result will make the server computer A105 the candidate of a copy place, if less than cost A2. This processing is repeated and the server computer by which communication cost becomes the minimum is looked for. Based on the information acquired by selection of this copy dimension partial file, and selection of a copy place server computer, a partial file is copied (Step 2403) and surveillance processing of Step 2401 is continued again.
[0191] Thus, the average of the access time to the partial file from a client computer can be shortened by changing Step 2101 and Step 2102 of drawing 21 into Step 2401 and Step 2402 of drawing 24 . Moreover, although "communication time" is mentioned as the example as communication cost above, "delay" of communication time, "fluctuation (range of fluctuation) etc.", etc. are sufficient.
[0192] Moreover, in Step 2102 of drawing 21 , and Step 2402 of drawing 24 , although it checks whether the copy of a partial file is possible to the server computer of a copy place and the partial file is copied to it in Step 2103 and Step 2403, check processing of Step 2102 and Step 2402 can be omitted by copying a partial file, without checking whether the copy of a partial file is possible to a server computer at Step 2102 and Step 2402. When the copy of a partial file cannot be accepted by the server computer side of a copy place in Step 2103 and Step 2403 at this time [whether the server computer of a copy place copies a partial file in search of the copy place for copying a partial file further, and] Or you may make it notify having canceled the partial file transmitted to the copy and having canceled the partial file for a copy to the server computer of a copied material.
[0193] Moreover, although the partial file is only copied to the server computer of a copy place from the server computer of a copied material in Step 2103 of drawing 21 , and Step 2403 of drawing 24 with the gestalt of the 5th operation of a **** In addition to the copy processing, the partial file which may make it move to the server computer of a copied material is chosen from the partial files in the server computer of a copy place, and you may make it move to the server computer of the partial file move-origin. By this, a partial file cannot concentrate on one server computer, but concentration of the load to the storage of a specific server computer can be avoided.
[0194] Moreover, in Step 2102 of drawing 21 , in case the server computer of a copy place is chosen, the server computer list is set up beforehand, there is remaining capacity of enough of the storage section of storage out of the server computer under this server computer list, and the server computer in which a load has low storage can be chosen. The time for server selection can be shortened now by this.
[0195] (Gestalt 6 of operation) Drawing 25 is a flow chart which shows other algorithms of the distributed file copy section 2031 of the server computer A2005 in the distributed file management system shown in drawing 20 of operation. In the gestalt of this operation, it has the same composition as the gestalt of the 5th operation mentioned above, and if operation of the distributed file copy section is removed, same operation is performed. Hereafter, the algorithm of the distributed file copy section 2031 of operation is explained.
[0196] In drawing 25 , the distributed file copy section 2031 supervises first the load information table 401 (drawing 4) which the state Management Department 814 has managed by the predetermined time interval (Step 2501).
[0197] as for the distributed file copy section 2031, the "load" of the arbitrary storage sections of storage 115 exceeded values, such as a predetermined value [%], 80 [for example,] etc., -- detecting (Step 2501) -- the partial file included in the detected storage is discovered with reference to the partial file control table 1301 (drawing 13) And "the access information per unit time" on the discovered partial file is acquired from the access information table 1201. "The

number of times of access" of the acquired "the access information per unit time" is compared, and the partial file which is biggest "number of times of access" is chosen as a copy dimension partial file (Step 2502). Here, suppose that the partial file A1 was chosen, for example.
[0198] Next, based on the external load information table 901 (drawing 9), there is "remaining capacity" of enough of the storage section of storage, and two or more server computers in which a "load" has low storage from a predetermined value are chosen. And it checks whether a partial file can be copied to the selected server computer, and the server computer which can be copied is determined as a copy place server computer (Step 2502).
[0199] Here, suppose that the storage 120 which has the storage section shown by the storage identifier DiskID1 of the server computer B106, and the storage 125 which has the storage section shown by the storage identifier DiskID2 of the server computer C107 were chosen.
[0200] Next, based on the information on the copy dimension partial file obtained at the above-mentioned step 2502, and a copy place server computer, a partial file is copied (Step 2503) and surveillance processing of Step 2501 is continued.
[0201] In an above-mentioned example, since the server computer B2006 and the server computer C2007 were chosen as the partial file A1 (126a) and a copy place computer as a copy dimension partial file at Step 2502 The distributed file copy section 2031 of the server computer A2005 of a copied material minds the partial file management section 111. The partial file A1 (126a) is read from storage 115, and it transmits to a network 101 by multicasting through a network interface 113. Moreover, the information about the "original address" (drawing 13) of the partial file A1 (126a) is also transmitted simultaneously.
[0202] On the other hand, by the server computer B2006 and computer C2007 of a copy place, the distributed file copy sections 2032 and 2033 receive through network interfaces 118 and 123, and write the partial file A1 (126a) transmitted from the server computer A2005 of a copied material in storage 120 and 125 through the partial file management sections 116 and 121. Moreover, the "original address" (drawing 13) of the partial file A1 (126a) is received, and it registers with each partial file control table 1402 and 1403 (drawing 14). Then, the server computer B2006 and the server computer C2007 of a copy place notify that the copy of the partial file A1 (126a) completed them to both and this server computer A2005 in the server computer shown in the server computer and an "original address" (drawing 13) of a copied material, respectively, i.e., this case, since both were the server computers A2005. The information on the partial file A1 (126a) of the partial file control table 1401 (drawing 14) is rewritten by the server computer A2005 shown in the server computer and an "original address" (drawing 13) of a copied material, i.e., a server computer.
[0203] As mentioned above, with the gestalt of this operation, since the candidate of the server computer of two or more copy places is chosen and a partial file is simultaneously copied to two or more selected server computers by multicasting communication in case the distributed file copy sections 2031, 2032, and 2033 copy a partial file to other server computers, the traffic in the case of the copy of a partial file is reducible.
[0204] (Gestalt 7 of operation) Drawing 26 is the block diagram showing an example of the gestalt of other operations of the distributed file management system in this invention. Here, in drawing 26, the same sign is given to the thing of the same composition as drawing 1. It set to drawing 26 and this distributed file management system is equipped with the networks 101, such as a Local Area Network which connects mutually two or more computers site A2602 equipped with the client computer group which consists of two or more client computers, such as server computers, such as a personal computer and a workstation, and a personal computer, and a workstation, the computer site B2603 and the computer site C2604, the computer site A2602 and the computer site B2603, and the computer site C2604, and a Wide Area Network.
[0205] Here, the computer site A2602 is equipped with two or more server computers (only "the server computer A2605" is shown in drawing 26), such as a personal computer and a workstation, and the client computer group A108 which consists of client computer 1-n (108-1 - 108-n), such as a personal computer and a workstation. This computer site A2602 has connected two or more server computers (only "the server computer A2605" is shown in drawing 26) and client computer groups A108 in the internal networks 131, such as Ethernet, for

example, has become the Internet domain.
[0206] Moreover, like the computer site A2602, the computer site B2603 was equipped with the client computer group B2609 which consists of two or more server computers (only "the server computer B2606" is shown in drawing 26), and two or more client computers, and the computer site C2604 is equipped with the client computer group C2610 which consists of two or more server computers (only "the server computer C2607" is shown in drawing 26), and two or more client computers. furthermore, these computer sites B2603 and the computer site C2604 — the computer site A2602 — the same — two or more server computers (in drawing 26, only the "server computer B2606" and the "server computer C2607" are shown), and the client computer groups B109 and the client computer groups C110 — each — it has connected in the internal network 132 and the internal network 133, for example, has become the Internet domain
[0207] The storage 115, such as a hard disk with which the server computer A2605 records the partial file of a distributed file, The network interface 113 for connecting with the internal networks 131, such as Ethernet The partial file management section 111 which controls the writing and read-out to the storage 115 which is recording the partial file, With the state Management Department 114 which supervises the load to storage 115, the remaining capacity of storage 115, and the load to a network interface 113, and holds the information about such loads and capacity It is constituted by the partial file management section 111, the state Management Department 114, and the distributed file management section 2612 connected to the network interface 113.
[0208] This distributed file management section 2612 directs writing and read-out of a partial file in the partial file management section 111. Moreover, when creating a distributed file, based on the information acquired from the state Management Department 114, the distributed file management section 2612 divides a distributed file into two or more partial files, and determines the server computer which arranges each partial file (record). Moreover, in referring to or updating the distributed file created before, it detects the server (recorded) computer by which the partial file of the corresponding distributed file exists. Here, the distributed file management section 2612 is equipped with the partial file size determination section 2631 which determines the size of the partial file at the time of dividing a distributed file to a partial file according to the kind of data recorded on information or a distributed file from a client computer.
[0209] The server computer B2606 and the server computer C2607 have the same composition as the server computer A2605. That is, the server computer B2606 is constituted by storage 120, a network interface 118, the partial file management section 116, the state Management Department 119, and the distributed file management section 2617. Moreover, the server computer C2607 is constituted by storage 125, a network interface 123, the partial file management section 121, the state Management Department 124, and the distributed file management section 2622. Moreover, the distributed file management sections 2617 and 2622 are equipped with the partial file size determination sections 2632 and 2633, respectively.
[0210] The difference with the distributed file management system shown in the distributed file management system shown in drawing 26 and drawing here is a point equipped with the partial file size determination sections 2631, 2632, and 2633 which determine the size of the partial file at the time of dividing a distributed file to a partial file according to the kind of data recorded on the distributed file management sections 2612, 2617, and 2622 by information or a distributed file from a client computer in the distributed file management system of drawing 26.
[0211] Operation of the partial file size determination sections 2631, 2632, and 2633 of the distributed file management system constituted as mentioned above is explained below.
[0212] In drawing 3, when the client computer 1 (108-1) performs the creation demand of the distributed file A to the server computer A2605, the partial file size determination section 2631 of the distributed file management section 2612 determines the size when assigning philharmonic a portion by processing of Step 302. It is good to make it decide with the directions from the kinds (for example, M-JPEG, MPEG1, MPEG 2, etc.) and the client computer 1 (108-1) of data which the partial file size determination section 2631 records on a distributed file to determine the size of a partial file in the case.
[0213] As mentioned above, in the distributed file management system of the gestalt of this

operation, the partial file size determination sections 2631, 2632, and 2633 of the distributed file management sections 2612, 2617, and 2622 can change suitably the size of the partial file which constitutes a distributed file by determining the size of the partial file at the time of dividing a distributed file to a partial file according to the kind of data recorded on information and a distributed file from a client computer etc. Thereby, it can prevent dividing into two or more partial files, a logic target, the data which have relation in content, for example, the data for one picture etc., etc.
[0214] (Gestalt 8 of operation) Next, the distributed file management section and the state Management Department which two or more server computers mentioned above have are summarized to one server computer, and the case where it manages intensively by this server computer is explained.
[0215] Drawing 27 shows an example of the composition of the distributed managerial system at the time of summarizing the distributed file management section and the state Management Department to one server computer in the distributed file management system in this invention shown in the gestalt of the 1st operation. In drawing 27, the same sign is given to the thing of the same composition as drawing 1.
[0216] The distributed file management system shown in drawing 27 Two or more computer sites A2702, the computer site B2703 equipped with the client computer group which consists of two or more client computers, such as server computers, such as a personal computer and a workstation, and a personal computer, and a workstation And the computer site X2710 equipped with the management server computer X2711 which manages intensively the distributed file arranged on the computer site C2704 and other server computers, It has the networks 101, such as a Local Area Network which connects the computer site A2702, the computer site B2703, the computer site C2704, and the computer site X2710 mutually, and a Wide Area Network.
[0217] Here, the computer site A2702 is equipped with two or more server computers (only "the server computer A2705" is shown in drawing 27), such as a personal computer and a workstation, and the client computer group A108 which consists of client computer 1-n (108-1 - 108-n), such as a personal computer and a workstation. This computer site A2702 has connected two or more server computers (only "the server computer A2705" is shown in drawing 27) and client computer groups A108 in the internal networks 131, such as Ethernet, for example, has become the Internet domain.
[0218] Moreover, like the computer site A2702, the computer site B2703 was equipped with the client computer group B109 which consists of two or more server computers (only "the server computer B2706" is shown in drawing 27), and two or more client computers, and the computer site C2704 is equipped with the client computer group C110 which consists of two or more server computers (only "the server computer C2707" is shown in drawing 27), and two or more client computers, furthermore, these computer sites B2703 and the computer site C2704 — the computer site A2702 — the same — two or more server computers (in drawing 27, only the "server computer B2706" and the "server computer C2707" are shown), and the client computer groups B109 and the client computer groups C110 — each — it has connected in the internal network 132 and the internal network 133, for example, has become the Internet domain
[0219] The server computer A2705 is constituted by the storage 115, such as a hard disk which records the partial file of a distributed file, the network interface 113 for connecting with the internal networks 131, such as Ethernet, and the partial file management section 111 that controls the writing and read-out to the storage 115 which is recording the partial file.
[0220] The server computer B2706 and the server computer C2707 have the same composition as the server computer A2705. That is, the server computer B2706 is constituted by storage 120, a network interface 118, and the partial file management section 116. Moreover, the server computer C2707 is constituted by storage 125, a network interface 123, and the partial file management section 121.
[0221] The network interface 2713 for connecting the management server computer X2711 to the internal networks 134, such as Ethernet With the state Management Department 2714 which supervises the load of the storage of each server computer, and the remaining capacity and the load of a network interface, and holds the information about a load Point to writing and read-out

of a partial file in the partial file management sections 111, 116, and 121 of each server computer, or In case a distributed file is created, a distributed file is divided into two or more partial files based on the information from the state Management Department 2714. In creating a partial file and referring to or updating a distributed file by determining the server computer which arranges each partial file It is constituted by the distributed file management section 2712 which detects the server computer which the partial file of the distributed file concerned referred to or updated ****, and performs the reference or updating of a partial file.

[0222] In drawing 27, the state after each distributed files A, B, and C were created is shown. That is, the partial file A1 (126a) of the distributed file A and the partial file B1 (126b) of the distributed file B are recorded on the storage 115 of the server computer A2705. Moreover, the partial file C1 (126e) of the distributed file C and the partial file C2 (126f) of the distributed file C are recorded on the storage 120 of the server computer B2706. Moreover, the partial file A2 (126c) of the distributed file A and the partial file A3 (126d) of the distributed file A are recorded on the storage 125 of the server computer C2707.

[0223] Next, operation of the distributed file management system constituted as mentioned above is explained. The creation demand of the distributed file A is published to the server computer A2705 from the client computer 1 (108-1) of the client computer group A108 below, and distributed processing in case the partial files A1-A3 as shown in drawing 27 are created is made into an example, and is explained. Here, the storage 115, 120, and 125 shown in drawing 27 shall have two or more storage sections or storage regions (only henceforth the "storage section"), respectively. Two or more of these storage sections may be one record medium physically, and may be two or more record media.

[0224] In drawing 27, the creation demand of the distributed file A is first published by the management server computer X2711 of the computer site X2710 from the client computer 1 (108-1). The creation demand of this distributed file A is received by the distributed file management section 2712 through the internal network 131 of the computer site A2702, a network 101, the internal network 134 of the computer site X2710, and the network interface 2713 of the management server computer A2711.

[0225] Drawing 28 is a flow chart which shows the algorithm of the distributed file management section 2712 at the time of receiving the creation demand of a distributed file of operation. Hereafter, detailed operation of the distributed file management section 2712 is explained using drawing 27 and drawing 28.

[0226] Refer to the load information which the state Management Department 2714 has managed for the distributed file management section 2712 first in drawing 28 (Step 2801).

[0227] At the state Management Department 2714, a load information table 401 like drawing 4 is managed, for example. In drawing 4, although the information about the server computer A2705 is shown, at the state Management Department 2714, the load information table 401 as shown in drawing 4 is prepared and managed for every server computer. The load information table 401 consists of a storage load information table 402 and a network load information table 403 in drawing 4. The storage load information table 402 consists of information on the "storage identifier" for discriminating each storage section of the storage connected to the server computer, the "load" of each storage section of storage, and the "remaining capacity" of each storage section of storage. The "load" of each storage section of storage is displayed by what [%] is used among the maximum transfer rates of the storage section. The network load information table 403 means towards which site the data transmitted through the network interface of each server computer are transmitted using the bandwidth of how much, and whether it has received by sending TETA which has received from which site using the bandwidth of how much. Moreover, a "sending out agency site" shows the computer site of the sending-out origin of data, a "sending-out place site" shows the computer site of the sending-out place of data, and the communication-band width of face for which "use bandwidth" is used between the computer site of a sending out agency and the computer site of a sending-out place is shown.

[0228] For example, when creating the distributed file A, about the storage section the storage identifier of the storage 115 of the server computer A2705 is indicated to be by DiskID1, the

"load" is 20 [%] and the distributed file management section 2712 can acquire the information that the "remaining capacity" is 10 [Mbytes].

[0229] Next, the distributed file management section 2712 is based on the "storage load information" acquired from the state Management Department 2714. From each storage sections of the storage connected to each server computer, the value of "remaining capacity" is larger than a predetermined value, and the value of a "load" chooses a predetermined value, for example, the storage which has the low storage section from 80 [%] (this value is determined according to the composition of a system or other equipments). And a partial file is assigned to the storage section of this storage in order. At this time, it is good to make size of a partial file into the same fixed length by all server computers. In quota processing of this partial file, it detects whether all partial files were able to be assigned (Step 2802).

[0230] Here, when creating the distributed file A, in drawing 27, the partial file A1 (126a) will be assigned to the server computer A2705, and the partial file A2 (126c) and the partial file A3 (126d) will be assigned to the server computer C2704.

[0231] When all partial files are able to be assigned, the distributed file management section 2712 registers the information for managing a distributed file into the distributed file control table 501 of drawing 5 and the partial file control table 601 of drawing 6 which were mentioned above (Step 2803).

[0232] In the above-mentioned example, as shown in drawing 5, the distributed file A consists of a partial file A1 (126a), a partial file A2 (126c), and a partial file A3 (126d).

[0233] Moreover, in drawing 6, the address of the partial file A1 (126a) is "file://siteA/serverA/DiskID1/(storage identifier DiskID1 of the server computer A105 of the computer site A102)." The address of the partial file A2 (126c) is "file://siteC/serverC/DiskID2/(storage identifier DiskID2 of the server computer C107 of the computer site C104)." The address of the partial file A3 (126d) expresses that it is "file://siteC/serverC/DiskID2/(storage DiskID2 of the server C107 of the computer site C104)."

[0234] Next, the distributed file management section 2712 gives the creation demand of a partial file to the partial file management section of the server computer which creates in order to create the partial file registered at Step 2803 on each corresponding server computer. Simultaneously with this creation demand, it directs to transmit data to the server computer which creates a direct partial file from the client computer 1 (108-1) to the client computer 1 (108-1) which performed the creation demand of a distributed file. By the server computer of which creation of a partial file was required, the data from the client computer 1 (108-1) are written in each storage section of storage by the partial file management section. The distributed file management section 2712 repeats this processing until creation of all partial files finishes (Step 2804).

[0235] Here, in creation of the partial file A1 (126a) of the distributed file A, the partial file management section 111 of the server computer A2705 writes the data from the client computer 1 (108-1) in the predetermined storage section of storage 115. Moreover, the partial file management section 121 of the server computer C2707 writes the data from the client computer 1 (108-1) in the predetermined storage section of storage 125, and creates the partial file A2 (126c) and the partial file A3 (126d).

[0236] On the other hand, at Step 2802, when all partial files are not able to be assigned, the distributed file management section 2712 notifies what creation processing of a distributed file went wrong to the client computer 1 (108-1) which performed the creation demand of a distributed file (Step 2805).

[0237] Next, the case where reference of a distributed file or the demand (henceforth "reference/updating demand") of updating is published from a client computer to a management server computer is explained. Moreover, the following explanation is described by making into an example the case where reference/updating demand of the distributed file A is published to the management server computer X2711 from the client computer 1 (108-1) in the client computer group A108.

[0238] First, reference/updating demand to the distributed file A published by the client computer 1 (108-1) is received by the distributed file management section 2712 through a

network interface 2713 in the management server computer X2711.
[0239] Drawing 29 is a flow chart which shows an algorithm of operation when the distributed file management section receives reference/updating demand of a distributed file. Hereafter, operation of the distributed file management section 2712 is explained using drawing 29.
[0240] First, the distributed file management section 2712 accepts reference/updating demand of the distributed file A from the client computer 1 (108-1), and it asks for the address of the partial file updated or referred to and its partial file from the distributed file control table 501 (drawing 5) and the partial file control table 601 (drawing 6) (Step 2901).
[0241] Here, in reference/updating demand of the distributed file A, the distributed file control table 501 (drawing 5) shows that the distributed file A is constituted by the partial file A1 (126a), the partial file A2 (126c), and the partial file A3 (126d). By the partial file control table 601 (drawing 6), moreover, the partial file A1 (126a) It exists in the storage section of the storage 115 shown by "file://siteA/serverA/DiskID1/". the partial file A2 (126c) It exists in the storage section of the storage 125 shown by "file://siteC/serverC/DiskID2/". the partial file A3 (126d) It turns out that it exists in the storage section of the storage 125 shown by "file://siteC/serverC/DiskID2/."
[0242] The distributed file management section 2712 performs reference/updating demand of the partial file concerned to the server computer holding the partial file corresponding to reference/updating demand from the client computer 1 (108-1). It is directed that the distributed file management section 2712 gives reference/updating demand to the server computer by which the partial file to which the client computer 1 (108-1) performs reference or updating exists to the client computer 1 (108-1) directly simultaneously with this demand. The partial file management section of each server computer writes in read-out (reference) of the partial file which exists in storage, or the partial file to storage based on reference/updating demand from the client computer 1 (108-1) according to the demand from the distributed file management section 2712 (Step 2902). (updating)
[0243] When it is the distributed file A here, in the partial file A1 (126a), the partial file A2 (126c) exists in the server computer C2707 of the computer site C2704, and the partial file A3 (126d) exists in the server computer A2705 of the computer site A2702 at the server computer C2707 of the computer site C2704. Therefore, processing of reference/updating demand to the partial file A1 (126a) is directly performed according to the demand from the distributed file management section 2712 between the client computer 1 (108-1) and the partial file management section 111. On the other hand, processing of reference/updating demand to the partial file A2 (126c) and the partial file A3 (126d) is directly performed according to the demand from the distributed file management section 2712 between the client computer 1 (108-1) and the server computer C2707.
[0244] As mentioned above, since management of a distributed file and management of the state of a system are performed [according to the distributed file management system of the gestalt of this operation] intensively in addition to the effect shown in the gestalt of the 1st operation, it is not necessary to have two or more duplicate Management Department, and simple [of the system configuration] can be carried out, and mitigation of cost can be aimed at.
[0245] in addition -- although explained as composition which concentrated the Management Department of distributed file management system which showed with the gestalt of the 1st operation on one management server computer in the distributed file management system of drawing 27 mentioned above -- the 2- it is applicable also to the distributed file management system of the gestalt of operation shown by the 7th
[0246] Moreover, although the Management Department of distributed file management system was explained as composition concentrated on one management server computer, you may make it form a management server computer in the distributed file management system of drawing 27 mentioned above for every computer site of every server computer of a predetermined group, and a predetermined group. If it does in this way, concentration of the load to the management server computer in a large-scale system can be prevented.
[0247] Moreover, you may make it choose at random the server computer which you may make it use a server computer in order based on a predetermined rule, and it not only chooses it as

order with only small the "load" of a server computer, but has the "load" below a predetermined threshold in the gestalt of operation mentioned above in selection of a partial file in case a partial file exists in two or more server **** on a plane.
[0248]
[Effect of the Invention] As mentioned above, since arrangement of a partial file was determined at each Management Department of a client computer to the server computer demanded according to the demand of creation of the distributed file to a server computer, reference, or updating or a management server computer based on the load information on each server computer according to the distributed file management equipment and distributed file management system of this invention, concentration of the load to a specific server computer could be avoided.
[0249] Moreover, since the external load information which notified load information to other server computers, and was notified from other server computers was held and arrangement of a partial file was determined based on the load information on other server computers, concentration of the load to a specific server computer could be avoided.
[0250] Moreover, since the partial file to which it is made to move was determined based on the access information, load information, and external load information for every partial file and a partial file was moved to other server computers, the imbalance of the capacity of concentration of the load to the storage of a specific server computer and the storage of each server computer could be avoided.
[0251] Moreover, since the partial file to copy was determined based on the access situation, load information, and external load information for every partial file and a partial file was copied to other server computers, concentration of the load to the storage of a specific server computer could be avoided.
[0252] Moreover, since the size of the partial file which divides and creates a distributed file according to the kind of data recorded on information and a distributed file from a client computer determines, the size of the partial file which constitutes a distributed file can change suitably, and it could prevent dividing and recording in the data which have relation content-wise and logically, for example, the data for one picture etc., to two or more partial files.
[0253] Moreover, since duplication of a resource was suppressed to the minimum by centralizing each Management Department which manages the partial file of a distributed file on one or more administrative server computers, the increase in cost could be suppressed.

[Translation done.]

* NOTICES *

1.This document has been translated by computer. So the translation may not reflect the original precisely.
2.**** shows the word which can not be translated.
3.In the drawings, any words are not translated.

DESCRIPTION OF DRAWINGS

[Brief Description of the Drawings]
[Drawing 1] It is the block diagram showing the distributed file management system of this invention.
[Drawing 2] It is drawing showing the composition of the distributed file in this invention.
[Drawing 3] It is the flow chart which shows the distributed file creation algorithm of the distributed file management section of this invention.
[Drawing 4] It is drawing showing an example of the load information table in this invention.
[Drawing 5] It is drawing showing an example of the distributed file control table of this invention.

[Drawing 6] It is drawing showing an example of the partial file control table of this invention.
[Drawing 7] It is the flow chart which shows reference/updating algorithm of the distributed file of the distributed file management section of this invention.
[Drawing 8] It is the block diagram showing the distributed file management system of this invention.
[Drawing 9] It is drawing showing an example of the external load information table in this invention.
[Drawing 10] It is the flow chart which shows the distributed file creation algorithm of the distributed file management section in this invention.
[Drawing 11] It is the block diagram showing the distributed file management system of this invention.
[Drawing 12] It is drawing showing an example of the partial file access information table in this invention.
[Drawing 13] It is drawing showing an example of the partial file control table in this invention.
[Drawing 14] It is drawing showing an example of the partial file control table in this invention.
[Drawing 15] It is the flow chart which shows the algorithm of the distributed file move section in this invention of operation.
[Drawing 16] It is drawing showing an example of the partial file control table in this invention.
[Drawing 17] It is drawing showing an example of the partial file control table in this invention.
[Drawing 18] It is the flow chart which shows the algorithm of the distributed file move section in this invention of operation.
[Drawing 19] It is drawing showing an example of the initial-entry table in this invention.
[Drawing 20] It is the block diagram showing the distributed file management system of this invention.
[Drawing 21] It is the flow chart which shows the algorithm of the distributed file copy section in this invention of operation.
[Drawing 22] It is drawing showing an example of the partial file control table in this invention.
[Drawing 23] It is drawing showing an example of the partial file control table in this invention.
[Drawing 24] It is the flow chart which shows the algorithm of the distributed file copy section in this invention of operation.
[Drawing 25] It is the flow chart which shows the algorithm of the distributed file copy section in this invention of operation.

[Drawing 26] It is the block diagram showing the distributed file management system of this invention.
[Drawing 27] It is the block diagram showing the distributed file management system of this invention.
[Drawing 28] It is the flow chart which shows the distributed file creation algorithm of the distributed file management section of this invention.
[Drawing 29] It is the flow chart which shows reference/updating algorithm of the distributed file of the distributed file management section of this invention.
[Drawing 30] It is the block diagram showing conventional distributed file management equipment.

[Description of Notations]
101 Network
102-104, 802-804, 1102-1104, 2002-2004, 2602-2604, and 2702- 2704 and 2710 Computer site
105-107, 805-807, 1105-1107, 2005-2007, 2605-2607, 2705-2707 Server computer
108, 109, 110 Client computer group
108-1 - 108-n Client computer
111, 116, 121 Partial file management section
112, 117, 122, 1112, 1117, 1122, 2012, 2017, 2022, 2612, 2617, 2622, 2712 Distributed file management section
113, 118, 123, 2713 Network interface
114, 119, 124, 814, 819, 824, 2714 State Management Department
115, 120, 125 Storage
126a-126f, 202-1 - 202-n Partial file
131-133 Internal network
401 Load Information Table
402 Storage Load Information Table
403 Network Load Information Table
501 Distributed File Control Table
601, 1301, 1401-1403, 1601-1603, 1701-1703, 2201-2203, 2301-2303 Partial file control table
811, 812, 813 External state Management Department
901 External Load Information Table
1131, 1132, 1133 Distributed file move section
1201 Access Information Table
1901 Initial-Entry Table
2031, 2032, 2033 Distributed file copy section
2631, 2632, 2633 Partial file size determination section
2711 Management Server Computer

[Translation done.]

(19)日本国特許庁（ＪＰ）　(12)**公開特許公報**（Ａ）　(11)特許出願公開番号
特開2000－207370
（P2000－207370A）
(43)公開日　平成12年７月28日(2000.7.28)

(51)Int.Cl.⁷		識別記号	FI			テーマコード(参考)
Ｇ０６Ｆ	15/177	６７４	Ｇ０６Ｆ	15/177	６７４Ａ	５Ｂ０４５
	12/00	５４５		12/00	５４５Ｂ	５Ｂ０８２
	15/16	６２０		15/16	６２０Ｂ	

審査請求　未請求　請求項の数31　ＯＬ　（全 42 頁）

(21)出願番号　特願平11－11513

(22)出願日　平成11年１月20日(1999.1.20)

(71)出願人　000005821
松下電器産業株式会社
大阪府門真市大字門真1006番地

(72)発明者　佐藤　正樹
大阪府門真市大字門真1006番地　松下電器産業株式会社内

(72)発明者　上杉　明夫
大阪府門真市大字門真1006番地　松下電器産業株式会社内

(74)代理人　100107526
弁理士　鈴木　直郁　（外１名）

最終頁に続く

(54)【発明の名称】　分散ファイル管理装置及び分散ファイル管理システム

(57)【要約】
【課題】　ファイルの作成、参照、更新において、複数のサーバ計算機で適切な負荷分散を行うことができる分散ファイル管理システムを提供する。
【解決手段】　本発明の分散ファイル管理システムは、サーバ計算機Ａ、Ｂ、Ｃと、クライアント計算機群１０８～１１０と、ネットワーク１０１とを備えている。サーバ計算機Ａ１０５は、部分ファイルを記録する記憶装置１１５と、ネットワークインタフェース１１３と、部分ファイルの書き込みや読み出しを制御する部分ファイル管理部１１１と、負荷を監視し、負荷情報を保持する状態管理部１１４と、分散ファイル管理部１１２とによって構成されている。各サーバ計算機Ａ、Ｂ、Ｃの負荷情報に基づいて部分ファイルの配置を決定するため、特定のサーバ計算機への負荷の集中を回避することができる

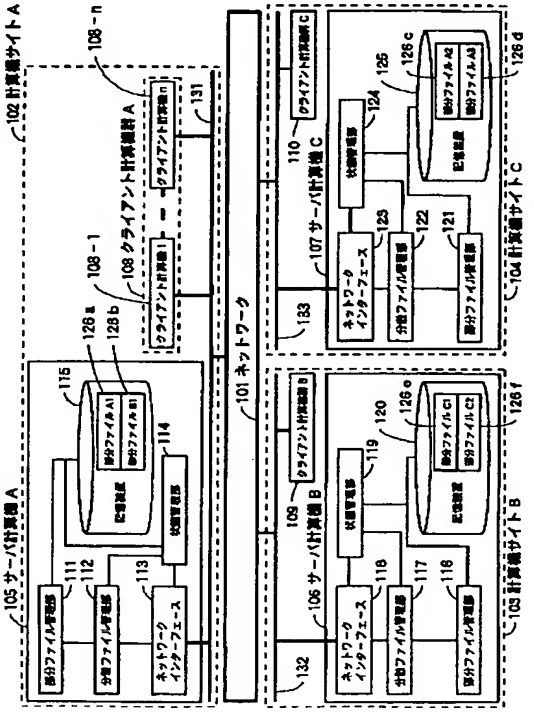

【特許請求の範囲】
【請求項１】データを記憶する記憶手段を有する複数のサーバ計算機と１または複数のクライアント計算機とが接続されているネットワークに接続された分散ファイル管理装置であって、
前記複数のサーバ計算機の負荷情報を保持して管理する状態管理手段と、
前記クライアント計算機からの分散ファイルの処理要求に対応して、前記分散ファイルの部分ファイルを特定し、前記状態管理手段で管理されている前記負荷情報に基づいて、前記部分ファイルを処理するサーバ計算機を決定する分散ファイル管理手段と、
を備える、ことを特徴とする分散ファイル管理装置。
【請求項２】前記状態管理手段は、他の分散ファイル管理装置へ前記負荷情報を通知し、また、他の分散ファイル管理装置から通知されたサーバ計算機の負荷情報を外部負荷情報として保持する外部状態管理手段を備える、ことを特徴とする請求項１記載の分散ファイル管理装置。
【請求項３】前記外部状態管理手段は、マルチキャストによって前記他の分散ファイル管理装置へ前記負荷情報を通知する、ことを特徴とする請求項２記載の分散ファイル管理装置。
【請求項４】前記外部状態管理手段は、前記他の分散ファイル管理装置のうち、隣接する他の分散ファイル管理装置に前記負荷情報を通知する、ことを特徴とする請求項２または３記載の分散ファイル管理装置。
【請求項５】複数のサーバ計算機と、１または複数のクライアント計算機と、前記複数のサーバ計算機及び前記１または複数のクライアント計算機を接続するネットワークとを備えた分散ファイル管理システムにおいて、
前記複数のサーバ計算機の各々は、
分散ファイルの一部または全部を構成する部分ファイルを記憶する記憶手段と、
負荷情報を保持して管理する状態管理手段と、
前記クライアント計算機からの分散ファイルの処理要求に対応して、前記分散ファイルの部分ファイルを特定し、前記状態管理手段で管理されている前記負荷情報に基づいて、前記部分ファイルを処理するサーバ計算機を決定する分散ファイル管理手段と、
を備える、
ことを特徴とする分散ファイル管理システム。
【請求項６】前記状態管理手段は、他のサーバ計算機へ前記負荷情報を通知し、また、他のサーバ計算機から通知された当該他のサーバ計算機の負荷情報を外部負荷情報として保持する外部状態管理手段を備える、ことを特徴とする請求項５記載の分散ファイル管理システム。
【請求項７】前記外部状態管理手段は、マルチキャストによって前記他のサーバ計算機へ前記負荷情報を通知する、ことを特徴とする請求項６記載の分散ファイル管理システム。
【請求項８】前記複数のサーバ計算機は、１または複数のサーバ計算機群にグループ分けされており、
前記外部状態管理手段は、前記１または複数のサーバ計算機群のうち、所定のサーバ計算機群に属する他のサーバ計算機へ前記負荷情報を通知する、
ことを特徴とする請求項６または７記載の分散ファイル管理システム。
【請求項９】前記複数のサーバ計算機は、１または複数のサーバ計算機群にグループ分けされており、
前記外部状態管理手段は、前記１または複数のサーバ計算機群のうち、隣接するサーバ計算機群に属する他のサーバ計算機に前記負荷情報を通知する、
ことを特徴とする請求項６または７記載の分散ファイル管理システム。
【請求項１０】前記分散ファイル管理手段は、前記部分ファイル毎のアクセス情報、前記負荷情報、及び前記外部負荷情報に基づいて移動する部分ファイルと移動先の他のサーバ計算機を決定し、該部分ファイルを該サーバ計算機へ移動する分散ファイル移動手段を備える、ことを特徴とする請求項２乃至４記載の分散ファイル管理装置または６乃至９記載の分散ファイル管理システム。
【請求項１１】前記分散ファイル移動手段は、前記負荷情報に含まれる前記記憶手段の負荷が所定の値よりも大であることを検知し、前記外部負荷情報と前記アクセス情報に基づいて移動する部分ファイルと移動先の他のサーバ計算機を決定し、該部分ファイルを該他のサーバ計算機へ移動する、ことを特徴とする請求項１０記載の分散ファイル管理装置または分散ファイル管理システム。
【請求項１２】前記分散ファイル移動手段は、前記負荷情報に含まれる前記記憶手段の残容量が所定の値より小であることを検知し、前記外部負荷情報と前記アクセス情報に基づいて移動する部分ファイルと移動先の他のサーバ計算機を決定し、該部分ファイルを該他のサーバ計算機へ移動する、ことを特徴とする請求項１０記載の分散ファイル管理装置または分散ファイル管理システム。
【請求項１３】前記分散ファイル移動手段は、前記負荷情報に含まれる前記ネットワークの負荷が所定の値よりも大であることを検知し、前記外部負荷情報と前記アクセス情報に基づいて移動する部分ファイルと移動先の他のサーバ計算機を決定し、該部分ファイルを該他のサーバ計算機へ移動する、ことを特徴とする請求項１０記載の分散ファイル管理装置または分散ファイル管理システム。
【請求項１４】前記分散ファイル移動手段は、前記負荷情報、前記外部負荷情報、前記アクセス情報、及び前記クライアント計算機と前記複数のサーバ計算機との間の接続情報に基づいて、前記部分ファイルを保持している記憶手段を有するサーバ計算機と処理要求を行ったクライアント計算機との間の通信コストを求め、該通信コス

トよりも小の通信コストとなる他のサーバ計算機を決定し、該他のサーバ計算機へ前記部分ファイルを移動する、ことを特徴とする請求項１０記載の分散ファイル管理装置または分散ファイル管理システム。

【請求項１５】前記分散ファイル移動手段は、前記部分ファイルの移動先となる前記他のサーバ計算機に対して、予め前記部分ファイルの移動が可能か否かを確認する、ことを特徴とする請求項１０乃至１４記載の分散ファイル管理装置または分散ファイル管理システム。

【請求項１６】前記分散ファイル移動手段は、前記部分ファイルを前記他のサーバ計算機へ移動した際に、前記他のサーバ計算機から前記サーバ計算機に他の部分ファイルを移動する、ことを特徴とする請求項１０乃至１５記載の分散ファイル管理装置または分散ファイル管理システム。

【請求項１７】前記分散ファイル移動手段は、前記部分ファイルを移動することができる他のサーバ計算機の候補をリストにし、該リストに基づいて、前記部分ファイルを移動する他のサーバ計算機を決定する、ことを特徴とする請求項１０乃至１６記載の分散ファイル管理装置または分散ファイル管理システム。

【請求項１８】前記分散ファイル移動手段は、前記部分ファイルの移動と共に、前記部分ファイルを作成したサーバ計算機に関する情報を前記他のサーバ計算機に送る、ことを特徴とする請求項１０乃至１７記載の分散ファイル管理装置または分散ファイル管理システム。

【請求項１９】前記分散ファイル管理手段は、前記部分ファイル毎のアクセス情報、前記負荷情報、及び前記外部負荷情報に基づいて、コピーする部分ファイルとコピー先の他のサーバ計算機を決定し、前記部分ファイルを前記他のサーバ計算機にコピーする分散ファイルコピー手段を備える、ことを特徴とする請求項２乃至４、６乃至１８記載の分散ファイル管理装置または分散ファイル管理システム。

【請求項２０】前記分散ファイルコピー手段は、前記負荷情報に含まれる前記記憶手段の負荷が所定の値よりも大であることを検知し、前記外部負荷情報と前記アクセス情報に基づいてコピーする部分ファイルとコピー先の他のサーバ計算機を決定し、該部分ファイルを該他のサーバ計算機へコピーする、ことを特徴とする請求項１９記載の分散ファイル管理装置または分散ファイル管理システム。

【請求項２１】前記分散ファイルコピー手段は、前記負荷情報に含まれる前記ネットワークの負荷が所定の値よりも大であることを検知し、前記外部負荷情報と前記アクセス情報に基づいてコピーする部分ファイルと移動先の他のサーバ計算機を決定し、該部分ファイルを該他のサーバ計算機へコピーする、ことを特徴とする請求項１９記載の分散ファイル管理装置または分散ファイル管理システム。

【請求項２２】前記分散ファイルコピー手段は、前記負荷情報、前記外部負荷情報、前記アクセス情報、及び前記クライアント計算機と前記複数のサーバ計算機との間の接続情報に基づいて、前記部分ファイルを保持している記憶手段を有するサーバ計算機と処理要求を行ったクライアント計算機との間の通信コストを求め、該通信コストよりも小の通信コストとなる他のサーバ計算機を決定し、該他のサーバ計算機へ前記部分ファイルをコピーする、ことを特徴とする請求項１９記載の分散ファイル管理装置または分散ファイル管理システム。

【請求項２３】前記分散ファイルコピー手段は、前記部分ファイルのコピー先となる前記他のサーバ計算機に対して、予め前記部分ファイルのコピーが可能か否かを確認する、ことを特徴とする請求項１９乃至２２記載の分散ファイル管理装置または分散ファイル管理システム。

【請求項２４】前記分散ファイルコピー手段は、前記部分ファイルを前記他のサーバ計算機へコピーした際に、前記他のサーバ計算機から前記サーバ計算機に他の部分ファイルをコピーする、ことを特徴とする請求項１９乃至２３記載の分散ファイル管理装置または分散ファイル管理システム。

【請求項２５】前記分散ファイルコピー手段は、前記部分ファイルをコピーすることができる他のサーバ計算機の候補をリストにし、該リストに基づいて、前記部分ファイルをコピーする他のサーバ計算機を決定する、ことを特徴とする請求項１９乃至２４記載の分散ファイル管理装置または分散ファイル管理システム。

【請求項２６】前記分散ファイルコピー手段は、前記部分ファイルをコピーする複数のコピー先の他のサーバ計算機を選択し、選択された前記複数の他のサーバ計算機へマルチキャストによって同時に前記部分ファイルをコピーする、ことを特徴とする請求項１９乃至２５記載の分散ファイル管理装置及び分散ファイル管理システム。

【請求項２７】前記状態管理手段で管理されている前記負荷情報は、前記記憶手段の容量及び負荷、並びに前記ネットワークと前記複数のサーバ計算機との間の通信負荷を含む、ことを特徴とする請求項１乃至２６記載の分散ファイル管理装置または分散ファイル管理システム。

【請求項２８】さらに、前記サーバ計算機は、前記部分ファイルを前記記憶手段に書き込み、また、前記部分ファイルを前記記憶手段から読み出す部分ファイル管理手段を備える、ことを特徴とする請求項１乃至２７記載の分散ファイル管理装置または分散ファイル管理システム。

【請求項２９】前記分散ファイル管理手段は、
前記クライアント計算機からの前記処理要求が分散ファイルの作成要求の場合には、該分散ファイルを複数の部分ファイルに分割し、分割した部分ファイルを保持するサーバ計算機を前記状態管理手段で管理されている前記負荷情報に基づいて決定し、

前記クライアント計算機からの前記処理要求が分散ファイルの参照要求または更新要求の場合には、前記参照要求または前記更新要求の処理の対象となる部分ファイルの存在を決め、前記処理要求を処理するサーバ計算機を前記状態管理手段で管理されている前記負荷情報に基づいて決定する、
ことを特徴とする請求項１乃至２８記載の分散ファイル管理装置または分散ファイル管理システム。
【請求項３０】前記分散ファイル管理手段は、前記クライアント計算機からの情報に基づいて、分散ファイルの一部または全部を構成する前記部分ファイルのサイズを決定する部分ファイルサイズ決定手段を備える、ことを特徴とする請求項１乃至２９記載の分散ファイル管理装置または分散ファイル管理システム。
【請求項３１】前記分散ファイル管理手段は、分散ファイルに記録されているデータの種類に基づいて、前記分散ファイルの一部または全部を構成する前記部分ファイルのサイズを決定する部分ファイルサイズ決定手段を備える、ことを特徴とする請求項１乃至２９記載の分散ファイル管理装置または分散ファイル管理システム。
【発明の詳細な説明】
【０００１】
【発明の属する技術分野】本発明は、コンピュータネットワークシステムにおいて複数の端末にファイルを分散して管理する分散ファイル管理装置及び分散ファイル管理システムに関する。特には、複数のサーバ計算機及びクライアント計算機をネットワークで接続したサーバ・クライアント型のコンピュータネットワークシステムにおいて、複数のサーバ計算機でファイルを分散して管理する分散ファイル管理装置及び分散ファイル管理システムに関する。
【０００２】
【従来の技術】従来から、複数のサーバ計算機及びクライアント計算機をネットワークで接続したサーバ・クライアント型のコンピュータネットワークシステム（以下、単に「ネットワークシステム」ともいう）に適用される分散ファイル管理技術として、例えば、特開平８－７７０５４号広報に開示されている分散ファイルシステムなどがある。
【０００３】図３０は、特開平８－７７０５４号広報に開示されている従来の分散ファイルシステムを示す。図３０において、この従来の分散ファイルシステムは、複数のサーバ計算機３００２、３００３、３００４、３００５と、複数のクライアント計算機３００６、３００７、３００８と、これら複数のサーバ計算機３００２、３００３、３００４、３００５及び複数のクライアント計算機３００６、３００７、３００８を接続するネットワーク３００１と、を備えている。
【０００４】ここで、サーバ計算機３００２には、分散ファイルＡの部分ファイルＡ－１（３００２－１）と分散ファイルＢの部分ファイルＢ－１（３００２－３）が保持されている。また、サーバ計算機３００３には、分散ファイルＡの部分ファイルＡ－２（３００３－１）と分散ファイルＢの部分ファイルＢ－２（３００３－２）が保持されている。また、サーバ計算機３００４には、分散ファイルＡの部分ファイルＡ－３（３００４－１）と分散ファイルＢの部分ファイルＢ－３（３００４－２）が保持されている。
【０００５】また、サーバ計算機３００５は、各サーバ計算機３００２、３００３、３００４に保持されているそれぞれの部分ファイルＡ－１～Ａ－３、Ｂ－１～Ｂ－３を管理する分散ファイル管理部３００５－２を備え、クライアント計算機３００６、３００７、３００８からの部分ファイルの参照要求または更新要求（以下、単に「参照／更新要求」ともいう）に対してその振り分けを行なうための参照／更新要求振り分け情報３００５－１を保持している。
【０００６】一方、クライアント計算機３００６は、分散ファイル作成要求に応じて分散ファイルの部分ファイルを作成する分散ファイル作成部３００６－１と、分散ファイルに対する更新要求に応じて、サーバ計算機３００５の参照／更新要求振り分け情報３００５－１に基づいて該分散ファイルの部分ファイルの所在を決定する更新要求振り分け部３００６－２と、分散ファイルに対する参照要求に応じて、サーバ計算機３００５の参照／更新要求振り分け情報３００５－１に基づいて該分散ファイルの部分ファイルの所在を決定する参照要求振り分け部３００６－３と、を備えている。なお、他のクライアント計算機３００７、３００８も同様の構成になっている。
【０００７】上述した従来の分散ファイルシステムによれば、例えば、クライアント計算機３００６の利用者が分散ファイルの作成を要求した場合、クライアント計算機３００６の分散ファイル作成部３００６－１は、予め決められている振り分け条件に基づいて当該分散ファイルの部分ファイルを作成するサーバ計算機を決定し、該サーバ計算機に分散ファイルの部分ファイルを作成する。そして、この部分ファイルの作成と同時に、どのサーバ計算機に部分ファイルを作成したかを表す参照／更新要求振り分け情報３００５－１を生成する。この参照／更新要求振り分け情報３００５－１は、ネットワーク３００１を介してサーバ計算機３００５に送信され、サーバ計算機３００５で保持される。
【０００８】また、例えば、クライアント計算機３００６の利用者が分散ファイルを参照または更新する参照／更新要求を行なった場合、まず、クライアント計算機３００６は、サーバ計算機３００５の分散ファイル管理部３００５－２に対して、該当する分散ファイルのオープン要求を行なう。サーバ計算機３００５の分散ファイル管理部３００５－２は、クライアント計算機３００６か

らの分散ファイルのオープン要求に対応して、クライアント計算機３００６へネットワーク３００１を介して当該分散ファイルに関する参照／更新要求振り分け情報３００５－１を送信する。クライアント計算機３００６の更新要求振り分け部３００６－２または参照要求振り分け部３００６－３は、サーバ計算機３００５から受け取った参照／更新要求振り分け情報３００５－１に基づいて、分散ファイルの部分ファイルを保持しているサーバ計算機に対し、参照／更新要求を送信する。

【０００９】このように、従来の分散ファイルシステムにおいては、分散ファイルを複数の部分ファイルに分割し、分散ファイルに対する処理（作成、参照、更新）を部分ファイル単位の処理に分散することにより、１つの分散ファイルに対して複数の処理要求が集中した場合にも、１つのサーバ計算機に負荷を集中させずに、負荷の分散を行なうことができる。

【００１０】

【発明が解決しようとする課題】しかしながら、図３０に示したような従来の分散ファイルシステムにおいては、分散ファイルを構成する部分ファイルを作成する際に、予め決められている固定的な振り分け規則に基づいて、該部分ファイルを作成するサーバ計算機を決定しているため、サーバ計算機へのファイルの分散において現実的なサーバ計算機の負荷情報を考慮したものにはなっていない。このため、実際には、アクセスや処理が集中して負荷の高くなっているサーバ計算機に対して、さらに部分ファイルの作成要求が発生することがある。そのため、特定のサーバ計算機のみの負荷が大きくなる場合があり、複数のサーバ計算機で適切な負荷分散が行なわれないという問題があった。

【００１１】また、従来の分散ファイルシステムにおいては、上記の振り分け規則に基づいて、一度固定的に部分ファイルの振り分けをサーバ計算機に行なってしまうと、その振り分け以後、すなわち、振り分けられたサーバ計算機での部分ファイルの作成以後には、作成された部分ファイルの移動やコピーを行なわないため、特定の部分ファイルへのアクセスが集中した場合、アクセスによる負荷の分散を行なうことができないという問題があった。

【００１２】したがって、本発明の目的は、ファイルの作成、参照、更新において、複数のサーバ計算機で適切な負荷分散を行うことができる分散ファイル管理装置及び分散ファイル管理システムを提供することである。

【００１３】

【課題を解決するための手段】上記課題を解決するために、本発明に係る第１の態様の分散ファイル管理装置は、　データを記憶する記憶手段を有する複数のサーバ計算機と１または複数のクライアント計算機とが接続されているネットワークに接続された分散ファイル管理装置であって、　複数のサーバ計算機の負荷情報を保持して管理する状態管理手段と、　クライアント計算機からの分散ファイルの処理要求に対応して、分散ファイルの部分ファイルを特定し、状態管理手段で管理されている負荷情報に基づいて、部分ファイルを処理するサーバ計算機を決定する分散ファイル管理手段と、を備えることを特徴とする。

【００１４】上述の本発明に係る分散ファイル管理装置において、　状態管理手段は、他の分散ファイル管理装置へ負荷情報を通知し、また、他の分散ファイル管理装置から通知されたサーバ計算機の負荷情報を外部負荷情報として保持する外部状態管理手段を備えることもできる。

【００１５】ここで、外部状態管理手段は、マルチキャストによって他の分散ファイル管理装置へ負荷情報を通知するようにしてもよい。また、外部状態管理手段は、他の分散ファイル管理装置のうち、隣接する他の分散ファイル管理装置に負荷情報を通知することもできる。

【００１６】また、上記課題を解決するために、本発明に係る第１の態様の分散ファイル管理システムは、　複数のサーバ計算機と、１または複数のクライアント計算機と、複数のサーバ計算機及び１または複数のクライアント計算機を接続するネットワークとを備えた分散ファイル管理システムにおいて、　複数のサーバ計算機の各々は、　分散ファイルの一部または全部を構成する部分ファイルを記憶する記憶手段と、　負荷情報を保持して管理する状態管理手段と、　クライアント計算機からの分散ファイルの処理要求に対応して、分散ファイルの部分ファイルを特定し、状態管理手段で管理されている負荷情報に基づいて、部分ファイルを処理するサーバ計算機を決定する分散ファイル管理手段と、を備えることを特徴とする。

【００１７】上述の本発明に係る分散ファイル管理システムにおいて、　状態管理手段は、他のサーバ計算機へ負荷情報を通知し、また、他のサーバ計算機から通知された当該他のサーバ計算機の負荷情報を外部負荷情報として保持する外部状態管理手段を備えるようにしてもよい。　ここで、外部状態管理手段は、マルチキャストによって他のサーバ計算機へ負荷情報を通知することもできる。

【００１８】また、上述の本発明に係る分散ファイル管理装置及び分散ファイル管理システムにおいて、　複数のサーバ計算機は、１または複数のサーバ計算機群にグループ分けされており、　外部状態管理手段は、１または複数のサーバ計算機群のうち、所定のサーバ計算機群に属する他のサーバ計算機へ負荷情報を通知するようにしてもよく、または、外部状態管理手段は、１または複数のサーバ計算機群のうち、隣接するサーバ計算機群に属する他のサーバ計算機に前記負荷情報を通知するようにしてもよい。

【００１９】さらに、分散ファイル管理手段は、部分フ

ァイル毎のアクセス情報、負荷情報、及び外部負荷情報に基づいて移動する部分ファイルと移動先の他のサーバ計算機を決定し、該部分ファイルを該サーバ計算機へ移動する分散ファイル移動手段を備えることもできる。

【００２０】ここで、分散ファイル移動手段は、負荷情報に含まれる記憶手段の負荷が所定の値よりも大であることを検知し、外部負荷情報とアクセス情報に基づいて移動する部分ファイルと移動先の他のサーバ計算機を決定し、該部分ファイルを該他のサーバ計算機へ移動するようにしてもよく、　または、分散ファイル移動手段は、負荷情報に含まれる記憶手段の残容量が所定の値より小であることを検知し、外部負荷情報とアクセス情報に基づいて移動する部分ファイルと移動先の他のサーバ計算機を決定し、該部分ファイルを該他のサーバ計算機へ移動するようにしてもよい。　また、分散ファイル移動手段は、負荷情報に含まれるネットワークの負荷が所定の値よりも大であることを検知し、外部負荷情報とアクセス情報に基づいて移動する部分ファイルと移動先の他のサーバ計算機を決定し、該部分ファイルを該他のサーバ計算機へ移動することもでき、　または、分散ファイル移動手段は、負荷情報、外部負荷情報、アクセス情報、及びクライアント計算機と複数のサーバ計算機との間の接続情報に基づいて、部分ファイルを保持している記憶手段を有するサーバ計算機と処理要求を行ったクライアント計算機との間の通信コストを求め、該通信コストよりも小の通信コストとなる他のサーバ計算機を決定し、該他のサーバ計算機へ部分ファイルを移動するようにしてもよい。

【００２１】さらに、分散ファイル移動手段は、部分ファイルの移動先となる他のサーバ計算機に対して、予め前記部分ファイルの移動が可能か否かを確認することもでき、　また、分散ファイル移動手段は、部分ファイルを他のサーバ計算機へ移動した際に、他のサーバ計算機からサーバ計算機に他の部分ファイルを移動することもできる。　さらに、分散ファイル移動手段は、部分ファイルを移動することができる他のサーバ計算機の候補をリストにし、該リストに基づいて、部分ファイルを移動する他のサーバ計算機を決定するようにしてもよい。

また、分散ファイル移動手段は、部分ファイルの移動と共に、部分ファイルを作成したサーバ計算機に関する情報を他のサーバ計算機に送るようにすることもできる。

【００２２】また、上述の分散ファイル管理手段は、部分ファイル毎のアクセス情報、負荷情報、及び外部負荷情報に基づいて、コピーする部分ファイルとコピー先の他のサーバ計算機を決定し、部分ファイルを他のサーバ計算機にコピーする分散ファイルコピー手段を備えることもできる。

【００２３】このとき、分散ファイルコピー手段は、負荷情報に含まれる記憶手段の負荷が所定の値よりも大であることを検知し、外部負荷情報とアクセス情報に基づいてコピーする部分ファイルとコピー先の他のサーバ計算機を決定し、該部分ファイルを該他のサーバ計算機へコピーするようにしてもよく、　分散ファイルコピー手段は、負荷情報に含まれるネットワークの負荷が所定の値よりも大であることを検知し、外部負荷情報とアクセス情報に基づいてコピーする部分ファイルと移動先の他のサーバ計算機を決定し、該部分ファイルを該他のサーバ計算機へコピーするようにしてもよい。　または、分散ファイルコピー手段は、負荷情報、外部負荷情報、アクセス情報、及びクライアント計算機と複数のサーバ計算機との間の接続情報に基づいて、部分ファイルを保持している記憶手段を有するサーバ計算機と処理要求を行ったクライアント計算機との間の通信コストを求め、該通信コストよりも小の通信コストとなる他のサーバ計算機を決定し、該他のサーバ計算機へ部分ファイルをコピーするようにすることもできる。

【００２４】ここで、分散ファイルコピー手段は、部分ファイルのコピー先となる他のサーバ計算機に対して、予め部分ファイルのコピーが可能か否かを確認するようにするとよい。　また、分散ファイルコピー手段は、部分ファイルを他のサーバ計算機へコピーした際に、他のサーバ計算機からサーバ計算機に他の部分ファイルをコピーしてもよい。　また、分散ファイルコピー手段は、部分ファイルをコピーすることができる他のサーバ計算機の候補をリストにし、該リストに基づいて、部分ファイルをコピーする他のサーバ計算機を決定するようにすることもできる。　さらに、分散ファイルコピー手段は、部分ファイルをコピーする複数のコピー先の他のサーバ計算機を選択し、選択された複数の他のサーバ計算機へマルチキャストによって同時に部分ファイルをコピーすることもできる。

【００２５】また、状態管理手段で管理されている負荷情報は、記憶手段の容量及び負荷、並びにネットワークと複数のサーバ計算機との間の通信負荷を含むことができる。

【００２６】さらに、上述の本発明に係る分散ファイル管理装置及び分散ファイル管理システムにおいて、　サーバ計算機は、部分ファイルを記憶手段に書き込み、また、部分ファイルを記憶手段から読み出す部分ファイル管理手段を備えることもできる。

【００２７】また、分散ファイル管理手段は、　クライアント計算機からの処理要求が分散ファイルの作成要求の場合には、該分散ファイルを複数の部分ファイルに分割し、分割した部分ファイルを保持するサーバ計算機を状態管理手段で管理されている負荷情報に基づいて決定し、　クライアント計算機からの処理要求が分散ファイルの参照要求または更新要求の場合には、参照要求または更新要求の処理の対象となる部分ファイルの存在を決め、処理要求を処理するサーバ計算機を状態管理手段で管理されている負荷情報に基づいて決定する、ようにし

てもよい。

【００２８】また、分散ファイル管理手段は、クライアント計算機からの情報に基づいて、分散ファイルの一部または全部を構成する部分ファイルのサイズを決定する部分ファイルサイズ決定手段を備えるようにすることができ、　または、分散ファイル管理手段は、分散ファイルに記録されているデータの種類に基づいて、分散ファイルの一部または全部を構成する部分ファイルのサイズを決定する部分ファイルサイズ決定手段を備えるようにしてもよい。

【００２９】上述の本発明に係る分散ファイル管理装置及び分散ファイル管理システムにおいては、分散ファイル管理手段が、サーバ計算機の負荷情報に基づいて、部分ファイルを配置するサーバ計算機を決定するため、特定のサーバ計算機への負荷の集中を回避することができる。

【００３０】また、分散ファイル管理手段が、他のサーバ計算機の負荷情報に基づいて、部分ファイルを配置するサーバ計算機を決定するため、特定のサーバ計算機で負荷が集中することを回避できる。

【００３１】また、部分ファイルを他のサーバ計算機に移動することによって、特定のサーバ計算機の記憶手段への負荷の集中や、記憶手段の容量の不均衡を回避することができる。また、部分ファイルを他のサーバ計算機にコピーすることによって、特定のサーバ計算機の記憶装置への負荷の集中を回避することができる。

【００３２】また、分散ファイルを構成する部分ファイルのサイズを適宜変更することができるため、論理的、内容的に関連のあるデータ、例えば、画像１フレーム分のデータなどを複数の部分ファイルに分割してしまうことを避けられる。

【００３３】

【発明の実施の形態】以下、本発明の分散ファイル管理装置及び分散ファイル管理システムの実施の形態について、図１から図２９を用いて説明する。

【００３４】（実施の形態１）図１は、本発明における分散ファイル管理システムの第１の実施の形態の一例を示す構成図である。図１において、この分散ファイル管理システムは、パーソナルコンピュータやワークステーションなどのサーバ計算機及びパーソナルコンピュータやワークステーションなどの複数のクライアント計算機から成るクライアント計算機群を備えた複数の計算機サイトＡ１０２、計算機サイトＢ１０３、及び計算機サイトＣ１０４と、計算機サイトＡ１０２、計算機サイトＢ１０３、及び計算機サイトＣ１０４を相互に接続するローカルエリアネットワークやワイドエリアネットワークなどのネットワーク１０１とを備えている。

【００３５】ここで、計算機サイトＡ１０２は、パーソナルコンピュータやワークステーションなどの複数のサーバ計算機（図１においては、「サーバ計算機Ａ１０５」のみ示す）と、パーソナルコンピュータやワークステーションなどのクライアント計算機１～ｎ（１０８－１～１０８－ｎ）から成るクライアント計算機群Ａ１０８とを備えている。この計算機サイトＡ１０２は、複数のサーバ計算機（図１においては、「サーバ計算機Ａ１０５」のみ示す）とクライアント計算機群Ａ１０８とをイーサネットなどの内部ネットワーク１３１で接続しており、例えば、インターネットドメインになっている。

【００３６】また、計算機サイトＡ１０２と同様に、計算機サイトＢ１０３は、複数のサーバ計算機（図１においては、「サーバ計算機Ｂ１０６」のみ示す）と、複数のクライアント計算機から成るクライアント計算機群Ｂ１０９とを備え、計算機サイトＣ１０４は、複数のサーバ計算機（図１においては、「サーバ計算機Ｃ１０７」のみ示す）と、複数のクライアント計算機から成るクライアント計算機群Ｃ１１０とを備えている。さらに、これらの計算機サイトＢ１０３及び計算機サイトＣ１０４は、計算機サイトＡ１０２と同様に、複数のサーバ計算機（図１においては、「サーバ計算機Ｂ１０６」及び「サーバ計算機Ｃ１０７」のみ示す）と、クライアント計算機群Ｂ１０９及びクライアント計算機群Ｃ１１０とを、それぞれ内部ネットワーク１３２及び内部ネットワーク１３３で接続しており、例えば、インターネットドメインになっている。

【００３７】サーバ計算機Ａ１０５は、分散ファイルの部分ファイルを記録するハードディスクなどの記憶装置１１５と、イーサネットなどの内部ネットワーク１３１へ接続するためのネットワークインタフェース１１３と、部分ファイルを記録している記憶装置１１５への書き込みや読み出しを制御する部分ファイル管理部１１１と、記憶装置１１５に対する負荷や記憶装置１１５の残り容量、及びネットワークインタフェース１１３に対する負荷を監視し、これらの負荷や容量に関する情報を保持する状態管理部１１４と、部分ファイル管理部１１１、状態管理部１１４、及びネットワークインタフェース１１３に接続された分散ファイル管理部１１２とによって構成されている。

【００３８】この分散ファイル管理部１１２は、部分ファイルの書き込みや読み出しを部分ファイル管理部１１１に指示する。また、分散ファイル管理部１１２は、分散ファイルを作成する場合には、状態管理部１１４から得られる情報に基づいて、分散ファイルを複数の部分ファイルに分割し、各部分ファイルを配置（記録）するサーバ計算機を決定する。また、以前に作成された分散ファイルを参照または更新する場合には、該当する分散ファイルの部分ファイルが存在する（記録されている）サーバ計算機を決定する。

【００３９】サーバ計算機Ｂ１０６及びサーバ計算機Ｃ１０７は、サーバ計算機Ａ１０５と同様の構成になっている。すなわち、サーバ計算機Ｂ１０６は、記憶装置１

２０と、ネットワークインタフェース１１８と、部分ファイル管理部１１６と、状態管理部１１９と、分散ファイル管理部１１７とによって構成されている。また、サーバ計算機Ｃ１０７は、記憶装置１２５と、ネットワークインタフェース１２３と、部分ファイル管理部１２１と、状態管理部１２４と、分散ファイル管理部１２２とによって構成されている。

【００４０】図２は、分散ファイルの構成の一例を示す図である。図２において、分散ファイル２０１は、複数の部分ファイル２０２－１～２０２－ｎによって構成されている。

【００４１】図１においては、各分散ファイルＡ、Ｂ、Ｃが作成された後の状態を示している。すなわち、サーバ計算機Ａ１０５の記憶装置１１５には、分散ファイルＡの部分ファイルＡ１（１２６ａ）と分散ファイルＢの部分ファイルＢ１（１２６ｂ）とが記録されている。また、サーバ計算機Ｂ１０６の記憶装置１２０には、分散ファイルＣの部分ファイルＣ１（１２６ｅ）と分散ファイルＣの部分ファイルＣ２（１２６ｆ）とが記録されている。また、サーバ計算機Ｃ１０７の記憶装置１２５には、分散ファイルＡの部分ファイルＡ２（１２６ｃ）と分散ファイルＡの部分ファイルＡ３（１２６ｄ）とが記録されている。

【００４２】次に、以上のように構成された分散ファイル管理システムの動作について説明する。以下においては、クライアント計算機群Ａ１０８のクライアント計算機１（１０８－１）からサーバ計算機Ａ１０５に対して分散ファイルＡの作成要求が発行され、図１に示したような部分ファイルＡ１～Ａ３が作成される場合の分散処理を例にして説明する。ここで、図１に示した記憶装置１１５、１２０、１２５は、それぞれ複数の記憶部または記憶領域（以下、単に「記憶部」ともいう）を有するものとする。これらの複数の記憶部は、物理的に１つの記録媒体であってもよく、また、複数の記録媒体であってもよい。

【００４３】図１において、まず、クライアント計算機１（１０８－１）からサーバ計算機Ａ１０５に分散ファイルＡの作成要求が発行される。この分散ファイルＡの作成要求は、内部ネットワーク１３１及びサーバ計算機Ａ１０５のネットワークインタフェース１１３を介して、サーバ計算機Ａ１０５の分散ファイル管理部１１２によって受け取られる。

【００４４】図３は、分散ファイルの作成要求を受け取った場合の分散ファイル管理部の動作アルゴリズムを示すフローチャートである。以下、図１及び図３を用いて、分散ファイル管理部１１２の詳細な動作を説明する。

【００４５】分散ファイルＡの作成要求を受け取った分散ファイル管理部１１２は、まず、状態管理部１１４の管理している負荷情報を獲得する（ステップ３０１）。

【００４６】図４は、状態管理部１１４で管理する負荷情報テーブル４０１を示す図である。図４において、負荷情報テーブル４０１は、記憶装置負荷情報テーブル４０２及びネットワーク負荷情報テーブル４０３から成っている。

【００４７】この記憶装置負荷情報テーブル４０２は、サーバ計算機Ａ１０５に接続されている記憶装置１１５の複数の記憶部を識別するための「記憶装置識別子」と、各記憶部の負荷情報［％］を示す「負荷」と、各記憶部の残容量［Mbytes］を示す「残容量」の項目で構成されている。ここで、記憶装置１１５の各記憶部の「負荷」は、記憶装置１１５の各記憶部の最大転送レートのうち何％を使用しているかを示している。

【００４８】また、ネットワーク負荷情報テーブル４０３は、ネットワークインタフェース１１３を介してネットワーク１０１上に送出するデータが、どの計算機サイト（送出先サイト）に向けて送出され、どの程度の帯域幅（使用通信帯域幅［Mbps］）を使用しているか、また、受信しているデータがどの計算機サイト（送出元サイト）から送られて来たものであり、どの程度の帯域幅（使用通信帯域幅［Mbps］）を使用して受信しているかを示している。この「送出元サイト」の項目がデータの送出元の計算機サイトを示し、「送出先サイト」の項目がデータの送出先の計算機サイトを示している。すなわち、ＳｉｔｅＡは計算機サイトＡ１０５を、ＳｉｔｅＢは計算機サイトＢ１０６を、ＳｉｔｅＣは計算機サイトＣ１０７を示している。ここで、送信元サイト及び送信先サイトを総称してネットワークリンク（以下、単に「リンク」ともいう）という。また、「使用通信帯域幅」の項目が、送出元サイトと送出先サイトとの間で使用されている通信帯域幅［Mbps］を示している。

【００４９】すなわち、分散ファイル管理部１１２が分散ファイルＡの作成要求を受け取った場合、分散ファイル管理部１１２は、例えば図４に示すように、状態管理部１１４から獲得した記憶装置負荷情報テーブル４０２の情報に基づいて、記憶装置識別子ＤｉｓｋＩＤ１の記憶部の負荷が２０［％］で、残容量が１０［Mbytes］であるという情報を得る（ステップ３０１）。

【００５０】次に、分散ファイル管理部１１２は、状態管理部１１４から得られる記憶装置負荷情報テーブル４０２の情報に基づいて、サーバ計算機Ａ１０５に接続されている記憶装置１１５の中から、残容量が十分に残っており、且つ負荷が所定の閾値より低い記憶部を選択して、該記憶部に対して部分ファイルを順に割り当てていく。ここで、閾値としては、例えば、８０［％］などを使用するとよい。但し、この閾値は、記憶装置１１５の構成などに応じて適宜決定することができる。また、部分ファイルのサイズは、固定長が望ましく、全てのサーバ計算機で同一のサイズにするとよい。このとき、全ての部分ファイルＡ１～Ａ３を記憶装置１１５の記憶部に

割り当てられた場合にはステップ３０４の処理を行う。一方、全ての部分ファイルＡ１～Ａ３を記憶装置１１５の記憶部に割り当てられなかった場合には、ステップ３０３の処理を行う（ステップ３０２）。

【００５１】本実施の形態（図１）の場合では、全ての部分ファイルＡ１～Ａ３を記憶装置１１５の記憶部に割り当てられなかった（ステップ３０２）ので、分散ファイルＡの部分ファイルＡ１（１２６ａ）をサーバ計算機Ａ１０５に割り当て、残りの部分ファイルＡ２、Ａ３を他のサーバ計算機Ｃ１０７に割り当てている。

【００５２】分散ファイル管理部１１２は、ステップ３０２で割り当てられなかった部分ファイルＡ２、Ａ３を他のサーバ計算機に割り当てるために、他のサーバ計算機に対して内部ネットワーク１３１及びネットワーク１０１を介して、部分ファイルＡ２、Ａ３の作成を行なえるかどうかの問い合わせを行なう。問い合わせを受けた他のサーバ計算機では、自己の状態管理部の負荷情報テーブル４０１を調べ、部分ファイルＡ２、Ａ３の作成が可能かどうかを返答する（ステップ３０３）。この部分ファイルの作成の問い合わせや返答の信号のやり取りは、各サーバ計算機の分散ファイル管理部がネットワークインタフェース及びネットワークを介して行うことになる。

【００５３】本実施の形態（図１）の場合では、分散ファイル管理部１１２が、ネットワークインタフェース１１３及びネットワーク１０１を介して、部分ファイルＡ２（１２６ｃ）及び部分ファイルＡ３（１２６ｄ）の作成を行なえるかどうかを計算機サイトＣ１０４のサーバ計算機Ｃ１０７の分散ファイル管理部１２２に問い合わせる。サーバ計算機Ｃ１０７の分散ファイル管理部１２２は、状態管理部１２４から得られる負荷情報テーブル４０１に基づいて、上述のステップ３０２と同様な判断を行ない、部分ファイルＡ２（１２６ｃ）及び部分ファイルＡ３（１２６ｄ）の作成を行えるかどうかの返答をサーバ計算機Ａ１０５に行なう（ステップ３０３）。図１の場合、サーバ計算機Ｃ１０７の記憶装置１２５には、部分ファイルＡ２（１２６ｃ）及び部分ファイルＡ３（１２６ｄ）を作成することができる。

【００５４】次に、サーバ計算機Ａの分散ファイル管理部１１２は、サーバ計算機Ａの記憶装置１１５に割り当てられた部分ファイルＡ１と、他のサーバ計算機Ｃの記憶装置１２５に割り当てられた部分ファイルＡ２、Ａ３とを管理するための情報を登録する（ステップ３０４）。

【００５５】図５は、分散ファイル管理テーブル５０１を示す図である。また、図６は、部分ファイル管理テーブル６０１を示す図である。図５において、分散ファイル管理テーブル５０１は、分散ファイルを識別するための「分散ファイル識別子」と、分散ファイルを構成する部分ファイルを識別するための「部分ファイル識別子リスト」の項目で構成されている。また、図６において、部分ファイル管理テーブル６０１は、部分ファイルを識別するための「部分ファイル識別子」と、部分ファイルの所在地を示す「所在地」の項目で構成されている。ここで、図６に示した「部分ファイル識別子」は、図５で示した「部分ファイル識別子リスト」を構成する「部分ファイル識別子」に対応している。

【００５６】本実施の形態（図１）の場合では、例えば、分散ファイルＡについて見ると、図５において、分散ファイルＡが、部分ファイルＡ１（１２６ａ）、部分ファイルＡ２（１２６ｃ）、部分ファイルＡ３（１２６ｄ）から構成されることを表している。また、図６において、部分ファイルＡ１（１２６ａ）の所在地が、「ｆｉｌｅ：／／ｓｉｔｅＡ／ｓｅｒｖｅｒＡ／ＤｉｓｋＩＤ１／（計算機サイトＡ１０２のサーバ計算機Ａ１０５の記憶装置識別子ＤｉｓｋＩＤ１）」であり、部分ファイルＡ２（１２６ｃ）の所在地が、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ２／（計算機サイトＣ１０４のサーバ計算機Ｃ１０７の記憶装置識別子ＤｉｓｋＩＤ２）」であり、部分ファイルＡ３（１２６ｄ）の所在地が、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ２／（計算機サイトＣ１０４のサーバＣ１０７の記憶装置ＤｉｓｋＩＤ２）」であることを表している。

【００５７】次に、分散ファイル管理部１１２は、サーバ計算機Ａの記憶装置１１５に部分ファイルＡ１を作成する場合、部分ファイル管理部１１１を介して、クライアント計算機１（１０８－１）からのデータを記憶装置１１５に書き込み、分散ファイルＡの部分ファイルＡ１の作成を行なう。また、他のサーバ計算機Ｃ１０７に部分ファイルＡ２、Ａ３を記録する場合、分散ファイル管理部１１２は、記録を行なうサーバ計算機Ｃ１０７の分散ファイル管理部１２２に部分ファイルＡ２、Ａ３の記録を依頼し、それと同時に、分散ファイルＡの作成要求を行なったクライアント計算機１（１０８－１）に指示をして、クライアント計算機１（１０８－１）から記録を行なうサーバ計算機Ｃ１０７に、直接データを送信するようにする。依頼を受けたサーバ計算機Ｃ１０７では、分散ファイル管理部１２２が部分ファイル管理テーブル６０１へ部分ファイルＡ２、Ａ３の登録を行なう。このようにして、他のサーバ計算機Ｃ１０７上に、部分ファイルＡ２、３が作成される（ステップ３０５）。

【００５８】以上のようにして、分散ファイルＡの部分ファイルＡ１（１２６ａ）の作成は、クライアント計算機１（１０８－１）からのデータを、サーバ計算機Ａ１０５の記憶装置１１５に書き込むことによって行なわれる。また、分散ファイルＡの部分ファイルＡ２（１２６ｃ）及び部分ファイルＡ３（１２６ｄ）の作成は、クライアント計算機１（１０８－１）からのデータを、直接サーバ計算機Ｃ１０７に送り、サーバ計算機Ｃ１０７の

記憶装置１２５に書き込むことによって行なわれる。

【００５９】また、上述のステップ３０３において、他の全てのサーバ計算機で、部分ファイルの作成が不可能な場合には、分散ファイル管理部１１２は、分散ファイルの作成要求を行なったクライアント計算機１（１０８－１）に対して、分散ファイルの作成に失敗したことを通知する（ステップ３０６）。

【００６０】一方、ステップ３０２で、分散ファイルの全ての部分ファイルの作成を、自己のサーバ計算機の記憶装置にできる場合、分散ファイル管理部１１２は、記憶装置１１５に割り当てられた分散ファイルを管理するための情報を、図５に示した分散ファイル管理テーブル５０１と図６に示した部分ファイル管理テーブル６０１に登録する（ステップ３０７）。

【００６１】次に、分散ファイル管理部１１２は、部分ファイル管理部１１１を介して、クライアント計算機１（１０８－１）からのデータを記憶装置１１５に書き込み、全ての部分ファイルの作成を行なう（ステップ３０８）。

【００６２】以上のように、本発明の分散ファイル管理システムによれば、分散ファイルの作成を、各サーバ計算機の負荷を考慮して行うため、適切に負荷分散ができるようになる。

【００６３】次に、クライアント計算機群Ａ１０８内のクライアント計算機１（１０８－１）からサーバ計算機Ａ１０５に対して分散ファイル参照／更新要求が発行された場合について説明する。

【００６４】まず、クライアント計算機１（１０８－１）から発行された分散ファイルＡに対する参照／更新要求は、サーバ計算機Ａ１０５において、ネットワークインタフェース１１３を介して、分散ファイル管理部１１２によって受け取られる。

【００６５】図７は、分散ファイルの参照／更新要求を受け取った場合の分散ファイル管理部の動作アルゴリズムを示すフローチャートである。以下、図７を用いて、分散ファイル管理部１１２の詳細な動作を説明する。また、以下においては、分散ファイルＡに対する参照／更新要求の処理を例にした具体的な動作についても説明する。

【００６６】まず、分散ファイル管理部１１２は、クライアント計算機１（１０８－１）からの分散ファイルの参照／更新要求に基づいて、分散ファイル管理テーブル５０１と部分ファイル管理テーブル６０１から、参照／更新する部分ファイルを特定し、その部分ファイルの所在地を求める（ステップ７０１）。

【００６７】ここで、クライアント計算機１（１０８－１）からの分散ファイルＡに対する参照／更新要求の場合、分散ファイル管理部１１２は、分散ファイル管理テーブル５０１に基づいて、分散ファイルＡが、部分ファイルＡ１（１２６ａ）、部分ファイルＡ２（１２６ｃ）、部分ファイルＡ３（１２６ｄ）によって構成されていることが解る。また、部分ファイル管理テーブル６０１に基づいて、部分ファイルＡ１（１２６ａ）の所在地が、「ｆｉｌｅ：／／ｓｉｔｅＡ／ｓｅｒｖｅｒＡ／ＤｉｓｋＩＤ１／（計算機サイトＡ１０２のサーバ計算機Ａ１０５の記憶装置識別子ＤｉｓｋＩＤ１）」であり、部分ファイルＡ２（１２６ｃ）の所在地が、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ２／（計算機サイトＣ１０４のサーバ計算機Ｃ１０７の記憶装置識別子ＤｉｓｋＩＤ２）」であり、部分ファイルＡ３（１２６ｄ）の所在地が、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ２／（計算機サイトＣ１０４のサーバＣ１０７の記憶装置ＤｉｓｋＩＤ２）」であることが解る。

【００６８】分散ファイル管理部１１２は、ステップ７０１で得られた部分ファイルの所在地から、参照／更新を行なう全ての部分ファイルが自己のサーバ計算機Ａ１０５の記憶装置１１５に存在するかどうか、あるいは一部または全部の部分ファイルが他のサーバ計算機に存在するかどうかの判定を行なう（ステップ７０２）。

【００６９】ここで、分散ファイルＡの場合、部分ファイルＡ１（１２６ａ）は、記憶装置１１５に存在し、部分ファィルＡ２（１２６ｃ）及び部分ファイルＡ３（１２６ｄ）は、計算機サイトＣ１０４のサーバ計算機Ｃ１０７の記憶装置１２５に存在することがわかる。

【００７０】次に、全ての部分ファイルが自己のサーバ計算機Ａ１０５の記憶装置１１５に存在しない場合（ステップ７０２）、ステップ７０１で得られた部分ファイルの所在地に基づいて、参照／更新を行なう部分ファイルが記録されている他のサーバ計算機に部分ファイルの存在を確かめる（ステップ７０３）。

【００７１】ここで、分散ファイルＡの場合には、部分ファイルＡ２（１２６ｃ）及び部分ファイルＡ３（１２６ｄ）の存在を、計算機サイトＣ１０４のサーバ計算機Ｃ１０７の分散ファイル管理部１２２に確認する。

【００７２】ステップ７０３で部分ファイルの存在が確認されたら、分散ファイル管理部１１２は、参照／更新を行なう部分ファイルが、自己のサーバ計算機Ａ１０５の記憶装置１１５に存在する場合には、クライアント計算機１（１０８－１）からの参照／更新要求に基づいて、部分ファイル管理部１１１を介して記憶装置１１５に存在する部分ファイルの読み出し（参照）や部分ファイルへの書き込み（更新）を行なう。また、参照／更新を行なう部分ファイルが、他のサーバ計算機の記憶装置に存在する場合、分散ファイル管理部１１２は、参照／更新を行なう部分ファイルを保持するサーバ計算機に該当部分ファイルの参照／更新を要求する。これと同時に、分散ファイル管理部１１２は、参照／更新要求を行なつたクライアント計算機１（１０８－１）が、参照／更新を行なう部分ファイルを保持するサーバ計算機に参

照／更新要求を直接行なうように指示する（ステップ７０４）。

【００７３】ここで、分散ファイルＡの場合、部分ファイルＡ１（１２６ａ）が計算機サイトＡ１０２のサーバ計算機Ａ１０５に、部分ファイルＡ２（１２６ｃ）及び部分ファイルＡ３（１２６ｄ）が計算機サイトＣ１０４のサーバ計算機Ｃ１０７に存在している。部分ファイルＡ１（１２６ａ）に対する参照／更新要求は、分散ファイル管理部１１２が、部分ファイル管理部１１１を介して、記憶装置１１５に対して参照／更新処理を行なう。一方、部分ファイルＡ２（１２６ｃ）及び部分ファイルＡ３（１２６ｄ）に対する参照／更新要求は、参照／更新要求を行ったクライアント計算機１（１０８－１）とサーバ計算機Ｃ１０７との間で、直接行われることになる。

【００７４】また、ステップ７０３で部分ファイルの存在が確認されなかった場合、分散ファイル管理部１１２は、分散ファイルの参照／変更要求を行ったクライアント計算機１（１０８－１）に、分散ファイルの参照／更新が失敗したことを通知する（ステップ７０５）。

【００７５】一方、ステップ７０２で、全ての部分ファイルが自己のサーバ計算機Ａ１０５の記憶装置１１５に存在する場合、分散ファイル管理部１１２は、クライアント計算機１（１０８－１）からの参照／更新要求に基づいて、部分ファイル管理部１１１を介して記憶装置１１５に存在する部分ファイルの読み出し（参照）や部分ファイルへの書き込み（更新）を行なう（ステップ７０６）。

【００７６】以上のように、上述した実施の形態によれば、クライアント計算機からサーバ計算機への要求が分散ファイルの作成の場合には、分散ファイルを複数の部分ファイルに分割し、サーバ計算機の負荷情報に基づいて各々の部分ファイルを作成するサーバ計算機を部分ファイル毎に決定して、分散ファイルの作成処理を行っている。また、クライアント計算機からの要求が分散ファイルの参照／更新の場合には、分散ファイルを構成する部分ファイルが存在するサーバ計算機を特定し、１または複数のサーバ計算機上に分散して配置されている部分ファイルをクライアント計算機から１つの分散ファイルとして扱うようにする。このようにして、クライアント計算機からサーバ計算機への分散ファイルの作成／参照／変更要求の際に、特定のサーバ計算機への負荷の集中をなくすことができる。

【００７７】（実施の形態２）図８は、本発明における分散ファイル管理システムの第２の実施の形態の一例を示す構成図である。この図８においては、図１と同様の構成には同一の符号を付している。図８に示した分散ファイル管理システムは、パーソナルコンピュータやワークステーションなどのサーバ計算機及びパーソナルコンピュータやワークステーションなどの複数のクライアント計算機から成るクライアント計算機群を備えた複数の計算機サイトＡ８０２、計算機サイトＢ８０３、及び計算機サイトＣ８０４と、計算機サイトＡ８０２、計算機サイトＢ８０３、及び計算機サイトＣ８０４を相互に接続するローカルエリアネットワークやワイドエリアネットワークなどのネットワーク１０１とを備えている。

【００７８】ここで、計算機サイトＡ８０２は、パーソナルコンピュータやワークステーションなどの複数のサーバ計算機（図８においては、「サーバ計算機Ａ８０５」のみ示す）と、パーソナルコンピュータやワークステーションなどのクライアント計算機１～ｎ（１０８－１～１０８－ｎ）から成るクライアント計算機群Ａ１０８とを備えている。この計算機サイトＡ８０２は、複数のサーバ計算機（図８においては、「サーバ計算機Ａ８０５」のみ示す）とクライアント計算機群Ａ１０８とをイーサネットなどの内部ネットワーク１３１で接続しており、例えば、インターネットドメインになっている。

【００７９】また、計算機サイトＡ８０２と同様に、計算機サイトＢ８０３は、複数のサーバ計算機（図８においては、「サーバ計算機Ｂ８０６」のみ示す）と、複数のクライアント計算機から成るクライアント計算機群Ｂ１０９とを備え、計算機サイトＣ８０４は、複数のサーバ計算機（図８においては、「サーバ計算機Ｃ８０７」のみ示す）と、複数のクライアント計算機から成るクライアント計算機群Ｃ１１０とを備えている。さらに、これらの計算機サイトＢ８０３及び計算機サイトＣ８０４は、計算機サイトＡ８０２と同様に、複数のサーバ計算機（図８においては、「サーバ計算機Ｂ８０６」及び「サーバ計算機Ｃ８０７」のみ示す）と、クライアント計算機群Ｂ１０９及びクライアント計算機群Ｃ１１０とを、それぞれ内部ネットワーク１３２及び内部ネットワーク１３３で接続しており、例えば、インターネットドメインになっている。

【００８０】サーバ計算機Ａ８０５は、分散ファイルの部分ファイルを記録するハードディスクなどの記憶装置１１５と、イーサネットなどの内部ネットワーク１３１へ接続するためのネットワークインタフェース１１３と、部分ファイルを記録している記憶装置１１５への書き込みや読み出しを制御する部分ファイル管理部１１１と、記憶装置１１５に対する負荷や記憶装置１１５の残り容量、及びネットワークインタフェース１１３に対する負荷を監視し、これらの負荷や容量に関する情報を保持する状態管理部８１４と、部分ファイル管理部１１１、状態管理部８１４、及びネットワークインタフェース１１３に接続された分散ファイル管理部１１２とによって構成されている。

【００８１】この状態管理部８１４は、他のサーバ計算機へ負荷情報を通知し、また、他のサーバ計算機から通知された外部負荷情報を保持する外部状態管理部８１１を備えている。

【００８２】サーバ計算機Ｂ８０６及びサーバ計算機Ｃ８０７は、サーバ計算機Ａ８０５と同様の構成になっている。すなわち、サーバ計算機Ｂ８０６は、記憶装置１２０と、ネットワークインタフェース１１８と、部分ファイル管理部１１６と、外部状態管理部８１２を備えた状態管理部８１９と、分散ファイル管理部１１７とによって構成されている。また、サーバ計算機Ｃ８０７は、記憶装置１２５と、ネットワークインタフェース１２３と、部分ファイル管理部１２１と、外部状態管理部８１３を備えた状態管理部８２４と、分散ファイル管理部１２２とによって構成されている。

【００８３】ここで、図８に示した分散ファイル管理システムと図１に示した分散ファイル管理システムとの相違点は、図８に示した状態管理部８１４、８１９、８２４が、他のサーバ計算機へ負荷情報を通知し、他のサーバ計算機から通知された外部負荷情報を保持する外部状態管理部８１１、８１２、８１３を備えている点である。

【００８４】図９は、外部状態管理部８１１、８１２、８１３で管理されている外部負荷情報テーブル９０１の一例を示す。図９において、外部負荷情報テーブル９０１は、サーバ計算機の所在地を示す「サーバ計算機所在地」と、サーバ計算機所在地で示されるサーバ計算機の記憶装置の負荷情報を示す「記憶装置負荷情報」の項目で構成されている。また、「記憶装置負荷情報」は、記憶装置を識別するための「記憶装置識別子」と、記憶装置の負荷を示す「負荷」と、記憶装置の残容量を示す「残容量」の項目で構成されている。

【００８５】外部状態管理部８１１、８１２、８１３は、外部負荷情報テーブル９０１からの外部負荷情報を他のサーバ計算機へ通知するために、以下のような動作を行なう。

【００８６】まず、外部状態管理部８１１、８１２、８１３は、定期的または所定のタイミングで状態管理部８１４、８１９、８２４に対して記憶装置負荷情報テーブル４０２に示される情報を問い合わせるか、または、状態管理部８１４、８１９、８２４から記憶装置負荷情報テーブル４０２に示される情報の状態変化を通知してもらうことにより、状態管理部８１４、８１９、８２４で管理されている記憶装置負荷情報テーブル４０２の情報を得る。

【００８７】次に、外部状態管理部８１１、８１２、８１３は、それぞれのネットワークインタフェース１１３、１１８、１２３を介して、各サーバ計算機に、記憶装置負荷情報を通知する。通知を受けたサーバ計算機では、それぞれネットワークインタフェース１１３、１１８、１２３を介して、外部状態管理部８１１、８１２、８１３が、記憶装置負荷情報を受け取り、それぞれの外部負荷情報テーブル９０１にこの情報を記録していく。

【００８８】以上のように構成された分散ファイル管理システムについて、クライアント計算機群Ａ１０８内のクライアント計算機１（１０８－１）からサーバ計算機Ａ８０５に対して分散ファイルＡの作成要求が発行された場合を例として説明する。

【００８９】まず、クライアント計算機１（１０８－１）から発行された分散ファイルＡの作成要求は、内部ネットワーク１３１及びサーバ計算機Ａ８０５のネットワークインタフェース１１３を介して、分散ファイル管理部１１２によって受け取られる。

【００９０】図１０は、分散ファイルの作成要求を受け取ったときの分散ファイル管理部の動作アルゴリズムを示すフローチャートである。以下、図１０を用いて、分散ファイル管理部の詳細な動作を説明する。本実施の形態では、第１の実施の形態で説明した図３に示すステップ３０２とステップ３０３の処理を統合して、１つのステップ１００２で処理することができる。

【００９１】まず、分散ファイル管理部１１２は、状態管理部８１４の管理している負荷情報テーブル４０１と、外部状態管理部８１１の管理している外部負荷情報テーブル９０１から各情報を獲得する（ステップ１００１）。

【００９２】この状態管理部１１４では、図４に示したような負荷情報テーブル４０１を管理している。図４において、負荷情報テーブル４０１は、記憶装置負荷情報テーブル４０２と、ネットワーク負荷情報テーブル４０３とによって構成されている。

【００９３】この記憶装置負荷情報テーブル４０２は、サーバ計算機Ａ１０５に接続されている記憶装置１１５の複数の記憶部を識別するための「記憶装置識別子」と、各記憶部の負荷情報［％］を示す「負荷」と、各記憶部の残容量［Mbytes］を示す「残容量」の項目で構成されている。ここで、記憶装置１１５の各記憶部の「負荷」は、記憶装置１１５の各記憶部の最大転送レートのうち何％を使用しているかを示している。

【００９４】また、ネットワーク負荷情報テーブル４０３は、ネットワークインタフェース１１３を介してネットワーク１０１上に送出するデータが、どの計算機サイト（送出先サイト）に向けて送出され、どの程度の帯域幅（使用通信帯域幅［Mbps］）を使用しているか、また、受信しているデータがどの計算機サイト（送出元サイト）から送られて来たものであり、どの程度の帯域幅（使用通信帯域幅［Mbps］）を使用して受信しているかを示している。この「送出元サイト」の項目がデータの送出元の計算機サイトを示し、「送出先サイト」の項目がデータの送出先の計算機サイトを示している。すなわち、ＳｉｔｅＡは計算機サイトＡ１０５を、ＳｉｔｅＢは計算機サイトＢ１０６を、ＳｉｔｅＣは計算機サイトＣ１０７を示している。ここで、送信元サイト及び送信先サイトを総称してネットワークリンク（以下、単に「リンク」ともいう）という。また、「使用通信帯域

幅」の項目が、送出元サイトと送出先サイトとの間で使用されている通信帯域幅［Mbps］を示している。

【００９５】また、外部状態管理部８１１は、図９に示したような外部負荷情報テーブル９０１を管理している。

【００９６】ここで、分散ファイルＡを作成する場合、分散ファイル管理部１１２は、状態管理部８１４の負荷情報テーブル４０１から、「記憶装置識別子」がＤｉｓｋＩＤ１で示される記憶装置１１５の記憶部の「負荷」が２０［％］で、「残容量」が１０［Mbytes］であるという情報を得ることができる。また、分散ファイル管理部１１２は、外部状態管理部８１４の外部負荷情報テーブル９０１から、計算機サイトＢ８０３のサーバ計算機Ｂ８０６の「記憶装置識別子」がＤｉｓｋＩＤ１で示される記憶装置１２０の記憶部の「負荷」が４９［％］で、「残容量」が１０００［Mbytes］であり、また、計算機サイトＣ８０４のサーバ計算機Ｃ８０７の「記憶装置識別子」がＤｉｓｋＩＤ１で示される記憶装置１２５の記憶部の「負荷」が３０［％］で、「残容量」が３０００［Mbytes］であるという情報を得ることができる。

【００９７】次に、分散ファイル管理部１１２は、まず、状態管理部８１４から得られる記憶装置負荷情報テーブル４０２に基づいて、サーバ計算機Ａ８０５に接続されている記憶装置１１５の各記憶部の中から、「残容量」が所定の容量以上で、且つ「負荷」が所定の閾値より低いという条件を満たす記憶部を選択し、分散ファイルを分割した部分ファイルを、当該条件を満たす各記憶部に順に割り当てていく。全ての部分ファイルを記憶装置１１５に割り当てられない場合には、分散ファイル管理部１１２は、外部状態管理部８１１から得られる外部負荷情報テーブル９０１の情報に基づいて、記憶部の「残容量」が所定の容量以上で、且つ「負荷」が所定の閾値より低い記憶部の存在する記憶装置を持つ他のサーバ計算機を選択する。そして、まだ割り当てられていない部分ファイルを、当該他のサーバ計算機の記憶装置の記憶部に順に割り当て、この割当てを当該他のサーバ計算機に通知する。そして、全ての部分ファイルがサーバ計算機の各記憶装置の記憶部に割り当てて作成できたか否かを判断する（ステップ１００２）。

【００９８】ここで、分散ファイルＡを作成する場合、分散ファイル管理部１１２は、状態管理部８１４の記憶装置負荷情報テーブル４０１に基づいて、部分ファイルＡ１（１２６ａ）をサーバ計算機Ａ８０５の記憶装置１１５の所定の記憶部に割り当てる。また、分散ファイル管理部１１２は、外部状態管理部８１１の外部負荷情報テーブル９０１の記憶装置負荷情報に基づいて、部分ファイルＡ２（１２６ｃ）及び部分ファイルＡ３（１２６ｄ）をサーバ計算機Ｃ８０７の記憶装置１２５の各記憶部に割り当てる。

【００９９】このように、サーバ計算機Ａ８０５は、外部状態管理部８１１から他のサーバ計算機の負荷や残容量の情報を得ることにより、他のサーバ計算機に部分ファイルの作成が可能かどうかの問い合わせをすることなく、他のサーバ計算機の負荷や残容量を考慮しながら部分ファイルを配置（記憶）するサーバ計算機を決めることができる。

【０１００】次に、分散ファイル管理部１１２は、分散ファイルの管理情報を、図５に示したような分散ファイル管理テーブル５０１と、図６に示したような部分ファイル管理テーブル６０１に登録する（ステップ１００３）。図５において、分散ファイル管理テーブル５０１は、分散ファイルを識別するための「分散ファイル識別子」と、分散ファイルを構成する部分ファイルを識別するための「部分ファイル識別子リスト」の項目で構成されている。また、図６において、部分ファイル管理テーブル６０１は、部分ファイルを識別するための「部分ファイル識別子」と、部分ファイルの所在地を示す「所在地」の項目で構成されている。ここで、図６に示した「部分ファイル識別子」は、図５で示した「部分ファイル識別子リスト」を構成する「部分ファイル識別子」に対応している。

【０１０１】ここで、分散ファイルＡの場合、図５において、分散ファイルＡが、部分ファイルＡ１（１２６ａ）、部分ファイルＡ２（１２６ｃ）、部分ファイルＡ３（１２６ｄ）から構成されることを表している。また、図６において、部分ファイルＡ１（１２６ａ）の所在地が、「ｆｉｌｅ：／／ｓｉｔｅＡ／ｓｅｒｖｅｒＡ／ＤｉｓｋＩＤ１／（計算機サイトＡ１０２のサーバ計算機Ａ１０５の記憶装置識別子ＤｉｓｋＩＤ１）」であり、部分ファイルＡ２（１２６ｃ）の所在地が、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ２／（計算機サイトＣ１０４のサーバ計算機Ｃ１０７の記憶装置識別子ＤｉｓｋＩＤ２）」であり、部分ファイルＡ３（１２６ｄ）の所在地が、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ２／（計算機サイトＣ１０４のサーバＣ１０７の記憶装置ＤｉｓｋＩＤ２）」であることを表している。

【０１０２】次に、分散ファイル管理部１１２は、記憶装置１１５の記憶部に部分ファイルを記録する場合には、部分ファイル管理部１１１を介して、クライアント計算機１（１０８－１）からのデータを記憶装置１１５の所定の記憶部に書き込む。また、他のサーバ計算機の記憶装置に部分ファイルを記録する場合には、分散ファイル管理部１１２は、記録を行なうサーバ計算機の分散ファイル管理部に部分ファイルの記録を依頼する。これと同時に、分散ファイル管理部１１２は、分散ファイルの作成要求を行なったクライアント計算機１（１０８－１）に指示して、記録を行なうサーバ計算機に直接データを送信するように指示する。分散ファイル管理部１１２から依頼を受けたサーバ計算機では、クライアント計

算機１（１０８－１）から部分ファイルのデータを受け取って、記憶装置の所定の記憶部に記録する。また、該サーバ計算機の分散ファイル管理部は、部分ファイル管理部の部分ファイル管理テーブル６０１へ部分ファイルの情報の登録を行なう。このようにして、他のサーバ計算機上に、部分ファイルが作成される（ステップ１００４）。

【０１０３】分散ファイルＡの場合、部分ファイルＡ１（１２６ａ）の作成は、クライアント計算機１（１０８－１）からのデータを記憶装置１１５の所定の記憶部に書き込むことによって行なわれる。部分ファイルＡ２（１２６ｃ）及び部分ファイルＡ３（１２６ｄ）の作成は、クライアント計算機１（１０８－１）から所定のデータを直接サーバ計算機Ｃ８０７に送り、サーバ計算機Ｃ８０７の記憶装置１２５の所定の記憶部にそれぞれ書き込むことによって行なわれる。

【０１０４】一方、ステップ１００２で、どのサーバ計算機にも部分ファイルを作成できない場合には、分散ファイル管理部１１２は、分散ファイル作成の要求を行なったクライアント計算機１（１０８－１）に対して、分散ファイルの作成に失敗したことを通知する（ステップ１００５）。

【０１０５】以上、分散ファイルの作成について説明したが、クライアント計算機からサーバ計算機に対して分散ファイルの参照／更新要求が発行された場合については、第１の実施の形態の場合（図７）と同様である。

【０１０６】以上のように、本発明の第２の実施の形態においては、状態管理部８１４、８１９、８２４が、他のサーバ計算機へ負荷情報を通知し、また、他のサーバ計算機から通知された外部負荷情報を保持する外部状態管理部８１１、８１２、８１３を備えることにより、分散ファイル管理部１１２、１１７、１２２は、他のサーバ計算機の負荷情報に基づいて、分散ファイルの部分ファイルを配置するサーバ計算機を決定することができ、特定のサーバ計算機への負荷の集中を回避することができる。

【０１０７】なお、外部状態管理部８１１、８１２、８１３から各サーバ計算機に記憶装置負荷情報を通知する際には、ユニキャストやマルチキャストを用いるとよい。特に、マルチキャストを用いた場合、全サーバ計算機に記憶装置負荷情報を一斉に通知することができ、通知のための通信量を減らすことができる。

【０１０８】また、通知するサーバ計算機をあらかじめ複数のグループに分けておき、各グループに属するサーバ計算機の各々にユニキャストで通知することもでき、また、各グループに対してマルチキャストで通知することもできる。このようにして、通知のための通信量を減らすことができる。

【０１０９】さらに、通知するサーバ計算機を隣接するサーバ計算機、すなわち、ネットワークで直接に接続されているサーバ計算機に限定して、ユニキャストあるいはマルチキャストによって通知することもできる。これにより、通知のための通信量を減らすことができる。

【０１１０】（実施の形態３）図１１は、本発明における分散ファイル管理システムの第３の実施の形態の一例を示す構成図である。この図１１においては、図８と同様の構成には同一の符号を付している。図１１に示した分散ファイル管理システムは、パーソナルコンピュータやワークステーションなどのサーバ計算機及びパーソナルコンピュータやワークステーションなどの複数のクライアント計算機から成るクライアント計算機群を備えた複数の計算機サイトＡ１１０２、計算機サイトＢ１１０３、及び計算機サイトＣ１１０４と、計算機サイトＡ１１０２、計算機サイトＢ１１０３、及び計算機サイトＣ１１０４を相互に接続するローカルエリアネットワークやワイドエリアネットワークなどのネットワーク１０１とを備えている。

【０１１１】ここで、計算機サイトＡ１１０２は、パーソナルコンピュータやワークステーションなどの複数のサーバ計算機（図１１においては、「サーバ計算機Ａ１１０５」のみ示す）と、パーソナルコンピュータやワークステーションなどのクライアント計算機１～ｎ（１０８－１～１０８－ｎ）から成るクライアント計算機群Ａ１０８とを備えている。この計算機サイトＡ１１０２は、複数のサーバ計算機（図１１においては、「サーバ計算機Ａ１１０５」のみ示す）とクライアント計算機群Ａ１０８とをイーサネットなどの内部ネットワーク１３１で接続しており、例えば、インターネットドメインになっている。

【０１１２】また、計算機サイトＡ１１０２と同様に、計算機サイトＢ１１０３は、複数のサーバ計算機（図１１においては、「サーバ計算機Ｂ１１０６」のみ示す）と、複数のクライアント計算機から成るクライアント計算機群Ｂ１０９とを備え、計算機サイトＣ１１０４は、複数のサーバ計算機（図１１においては、「サーバ計算機Ｃ１１０７」のみ示す）と、複数のクライアント計算機から成るクライアント計算機群Ｃ１１０とを備えている。さらに、これらの計算機サイトＢ１１０３及び計算機サイトＣ１１０４は、計算機サイトＡ１１０２と同様に、複数のサーバ計算機（図１１においては、「サーバ計算機Ｂ１１０６」及び「サーバ計算機Ｃ１１０７」のみ示す）と、クライアント計算機群Ｂ１０９及びクライアント計算機群Ｃ１１０とを、それぞれ内部ネットワーク１３２及び内部ネットワーク１３３で接続しており、例えば、インターネットドメインになっている。

【０１１３】サーバ計算機Ａ１１０５は、分散ファイルの部分ファイルを記録するハードディスクなどの記憶装置１１５と、イーサネットなどの内部ネットワーク１３１へ接続するためのネットワークインタフェース１１３と、部分ファイルを記録している記憶装置１１５への書

き込みや読み出しを制御する部分ファイル管理部１１１と、記憶装置１１５に対する負荷や記憶装置１１５の残り容量、及びネットワークインタフェース１１３に対する負荷を監視し、これらの負荷や容量に関する情報を保持する状態管理部８１４と、部分ファイル管理部１１１、状態管理部８１４、及びネットワークインタフェース１１３に接続された分散ファイル管理部１１１２とによって構成されている。

【０１１４】この状態管理部８１４は、他のサーバ計算機へ負荷情報を通知し、また、他のサーバ計算機から通知された外部負荷情報を保持する外部状態管理部８１１を備えている。

【０１１５】また、分散ファイル管理部１１１２は、部分ファイル毎のアクセス情報と負荷情報テーブル４０１及び外部負荷情報テーブル９０１の情報とに基づいて、移動させる部分ファイルを決定し、他のサーバ計算機へ部分ファイルを移動させる分散ファイル移動部１１３１を備えている。

【０１１６】サーバ計算機Ｂ１１０６及びサーバ計算機Ｃ１１０７は、サーバ計算機Ａ１１０５と同様の構成になっている。すなわち、サーバ計算機Ｂ１１０６は、記憶装置１２０と、ネットワークインタフェース１１８と、部分ファイル管理部１１６と、外部状態管理部８１２を備えた状態管理部８１９と、分散ファイル移動部１１３２を備えた分散ファイル管理部１１１７とによって構成されている。また、サーバ計算機Ｃ１１０７は、記憶装置１２５と、ネットワークインタフェース１２３と、部分ファイル管理部１２１と、外部状態管理部８１３を備えた状態管理部８２４と、分散ファイル移動部１１３３を備えた分散ファイル管理部１１２２とによって構成されている。

【０１１７】ここで、図１１に示した分散ファイル管理システムと図８に示した分散ファイル管理システムとの相違点は、図１１に示した分散ファイル管理部１１１２、１１１７、１１２２が、部分ファイル毎のアクセス情報と負荷情報テーブル４０１及び外部負荷情報テーブル９０１の情報とから、移動させる部分ファイルを決定し、他のサーバ計算機へ部分ファイルを移動させる分散ファイル移動部１１３１、１１３２、１１３３を備えている点である。

【０１１８】図１２は、状態管理部８１４で管理されている部分ファイル毎のアクセス情報テーブル１２０１の一例を示す。図１２において、このアクセス情報テーブル１２０１は、部分ファイルを識別するための「部分ファイル識別子」と、「単位時間あたりのアクセス情報」の項目で構成されている。また、「単位時間あたりのアクセス情報」は、部分ファイルにアクセスしているクライアント計算機の存在するサイトの情報である「アクセス元サイト識別子」と、部分ファイルへのアクセス回数を示す「アクセス回数」の項目から構成されている。このアクセス情報テーブル１２０１は、状態管理部８１４によって、単位時間毎に更新され続ける。

【０１１９】図１３は、分散ファイル管理部１１１２で管理されている部分ファイル管理テーブル１３０１の一例を示す。図１３において、部分ファイル管理テーブル１３０１は、部分ファイルを識別するための「部分ファイル識別子」と、部分ファイルの所在地を示す「所在地」と、部分ファイルが最初に作成された所在地を示す「オリジナル所在地」の項目から構成されている。図１３において、部分ファイルが作成された段階では、「所在地」と「オリジナル所在地」の示す情報は同一であるが、部分ファイルが他のサーバ計算機に移動するのに応じて、「所在地」の情報は変化する。図１３で示した部分ファイル管理テーブル１３０１は、図６で示した部分ファイル管理テーブル６０１に、「オリジナル所在地」の項目を加えたものになっている。

【０１２０】以上のように構成された分散ファイル管理システムにおいて、分散ファイルＡ、分散ファイルＢ、及び分散ファイルＣが、上述で示したようにしてサーバ計算機Ａ１１０５で作成された後、各分散ファイルの部分ファイルを移動する処理について詳細に説明する。

【０１２１】図１４は、サーバ計算機Ａ１１０５によって作成された分散ファイルＡ、分散ファイルＢ、及び分散ファイルＣの部分ファイル管理テーブル１３０１の内容の一例を示している。図１４において、図１４（Ａ）は、サーバ計算機Ａ１１０５の部分ファイル管理テーブル１４０１を示し、（Ｂ）はサーバ計算機Ｂ１１０６の部分ファイル管理テーブル１４０２を示し、（Ｃ）はサーバ計算機Ｃ１１０７の部分ファイル管理テーブル１４０３を示している。図１４（Ａ）の部分ファイル管理テーブル１４０１には、部分ファイル識別子が、Ａ１、Ａ２、Ａ３、Ｂ１、Ｃ１、Ｃ２で示される各部分ファイルの所在地と、オリジナル所在地が示されている。部分ファイル管理テーブル１４０２には、部分ファイル識別子が、Ｃ１、Ｃ２で示される各部分ファイルの所在地と、オリジナル所在地が示されている。部分ファイル管理テーブル１４０３には、部分ファイル識別子が、Ａ２、Ａ３で示される各部分ファイルの所在地と、オリジナル所在地が示されている。ここで、図１４においては、各部分ファイルの移動前の状態を表している。このため、全ての部分ファイルにおいて、その所在地とオリジナル所在地が一致している。

【０１２２】図１４に示した状態での部分ファイルの移動の際の、サーバ計算機Ａ１１０５の分散ファイル移動部１１３１の動作アルゴリズムについて説明する。

【０１２３】図１５は、分散ファイル移動部１１３１の動作アルゴリズムを示す。まず、分散ファイル移動部１１３１は、状態管理部８１４が管理している負荷情報テーブル４０１（図４）の情報を、一定時間の間隔で監視する（ステップ１５０１）。

【０１２４】分散ファイル移動部１１３１は、ある記憶装置の「負荷」が予め設定されている所定の閾値（例えば、８０％などの値で、この値は、システムの構成などによって任意に決定する）を越えたことを検出すると（ステップ１５０１）、この検出された記憶装置に含まれている部分ファイルの「部分ファイル識別子」を、部分ファイル管理テーブル１３０１を参照して探す。探し出した「部分ファイル識別子」の「単位時間当たりのアクセス情報」を、アクセス情報テーブル１２０１から得る。ここで得られた「単位時間当たりのアクセス情報」の「アクセス回数」を各「部分ファイル識別子」毎に比較し、最も大きな「アクセス回数」になっている「部分ファイル識別子」を選択する（ステップ１５０２）。すなわち、移動元部分ファイルを選択する。例えば、ここで、移動元部分ファイルとして部分ファイルＡ１（１２６ａ）が選択されたとする。

【０１２５】次に、分散ファイル移動部１１３１は、外部負荷情報テーブル９０１（図９）に基づいて、「残容量」が十分で且つ「負荷」が所定の値より低い記憶装置を持つサーバ計算機を選択する。そして、分散ファイル移動部１１３１は、選択したサーバ計算機に対して部分ファイルが移動できるかどうかを確認し、移動可能なサーバ計算機を決定する（ステップ１５０２）。すなわち、移動先サーバ計算機を選択する。例えば、ここで、サーバ計算機Ｃ１１０７の記憶装置識別子ＤｉｓｋＩＤ２で示される記憶装置１２５の記憶部が選択されたとする。

【０１２６】次に、この移動元部分ファイルの選択と移動先サーバ計算機の選択によって得られた情報に基づいて、部分ファイルの移動を行なう（ステップ１５０３）。

【０１２７】上述の例では、ステップ１５０２で、移動元部分ファイルとして部分ファイルＡ１（１２６ａ）、移動先サーバ計算機としてサーバ計算機Ｃ１１０７が選択されているので、移動元のサーバ計算機Ａ１１０５の分散ファイル移動部１１３１は部分ファイル管理部１１１を介して、記憶装置１１５から部分ファイルＡ１（１２６ａ）を読み出す。この読み出された部分ファイルＡ１（１２６ａ）は、部分ファイルＡ１（１２６ａ）の「オリジナル所在地」（図１３）に関する情報と共に、ネットワークインタフェース１１３及び内部ネットワーク１３１を介してネットワーク１０１へ送出される。

【０１２８】一方、移動先のサーバ計算機Ｃ１１０７において、分散ファイル移動部１１３３は、移動元のサーバ計算機Ａ１１０５より送出された部分ファイルＡ１（１２６ａ）とその「オリジナル所在地」の情報を、ネットワーク１０１から内部ネットワーク１３３及びネットワークインタフェース１２３を介して受信する。部分ファイル管理部１２１は、この受信した部分ファイルＡ１（１２６ａ）を記憶装置１２５に書き込む。また、部分ファイルＡ１（１２６ａ）の「オリジナル所在地」を、部分ファイル管理部１２１の部分ファイル管理テーブル（図１４（Ｃ））に登録する。

【０１２９】その後、移動先のサーバ計算機Ｃ１１０７は、移動元のサーバ計算機Ａ１１０５と「オリジナル所在地」（図１３）に示されているサーバ計算機（この例の場合では、サーバ計算機Ａ１１０５、すなわち、移動元とオリジナルは同じサーバ計算機Ａ１１０５）に対して、部分ファイルＡ１（１２６ａ）の移動が完了したことを通知する。移動元のサーバ計算機Ａ１１０５と「オリジナル所在地」に示されるサーバ計算機では、部分ファイル管理テーブルに登録されている部分ファイルＡ１（１２６ａ）の情報を書き換える。

【０１３０】図１６は、上述の例のように部分ファイルＡ１（１２６ａ）が移動した後の、図１４に示した部分ファイル管理テーブル１４０１、１４０２、１４０３の状態を示す。図１６において、図１６（Ａ）はサーバ計算機Ａ１１０５の部分ファイル管理テーブル１６０１を示し、（Ｂ）はサーバ計算機Ｂ１１０６の部分ファイル管理テーブル１６０２を示し、（Ｃ）はサーバ計算機Ｃ１１０７の部分ファイル管理テーブル１６０３を示している。すなわち、図１６（Ａ）～（Ｃ）の各部分ファイル管理テーブル１６０１、１６０２、１６０３は、それぞれ図１４（Ａ）～（Ｃ）の各部分ファイル管理テーブル１４０１、１４０２、１４０３に対応している。ここで、部分ファイル管理テーブル１６０１には、「部分ファイル識別子」がＡ１、Ａ２、Ａ３、Ｂ１、Ｃ１、Ｃ２で示される各部分ファイルの「所在地」と、「オリジナル所在地」が示されている。部分ファイル管理テーブル１６０２には、「部分ファイル識別子」がＣ１、Ｃ２で示される各部分ファイルの「所在地」と、「オリジナル所在地」が示されている。部分ファイル管理テーブル１６０３には、「部分ファイル識別子」がＡ１、Ａ２、Ａ３で示される各部分ファイルの「所在地」と、「オリジナル所在地」が示されている。ここで、図１６に示した部分ファイル管理テーブル１６０１、１６０２、１６０３の状態と図１４に示した部分ファイル管理テーブル１４０１、１４０２、１４０３の状態の差異は、部分ファイルＡ１（１２６ａ）を、サーバ計算機Ａ１１０５からサーバ計算機Ｃ１１０７へ移動させたことによるものである。すなわち、図１６と図１４の相違点は、図１４（Ａ）の部分ファイル管理テーブル１４０１において、部分ファイルＡ１（１２６ａ）の「所在地」が「ｆｉｌｅ：／／ｓｉｔｅＡ／ｓｅｒｖｅｒＡ／ＤｉｓｉＩＤ１／」であると登録されている情報が、図１６（Ａ）の部分ファイル管理テーブル１６０１においては、部分ファイルＡ１（１２６ａ）の「所在地」が「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ２／」と登録されている点と、図１６（Ｃ）の部分ファイル管理テーブル１６０３において部分ファイルＡ１の項目が追加

されている点である。

【０１３１】図１７は、さらに、この図１６に示した状態から、上述した処理と同様にして、サーバ計算機Ｂ１１０６の分散ファイル移動部１１３２が、部分ファイルＣ１（１２６ｅ）を、サーバ計算機Ｃ１１０７に移動させ、サーバ計算機Ｃ１１０７の分散ファイル移動部１１３３が、部分ファイルＡ１（１２６ａ）を、サーバ計算機Ｂ１１０６に移動させた場合の部分ファイル管理テーブルを示す。

【０１３２】図１７において、図１７（Ａ）はサーバ計算機Ａ１１０５の部分ファイル管理テーブル１７０１を示し、（Ｂ）はサーバ計算機Ｂ１１０６の部分ファイル管理テーブル１７０２を示し、（Ｃ）はサーバ計算機Ｃ１１０７の部分ファイル管理テーブル１７０３を示している。部分ファイル管理テーブル１７０１には、「部分ファイル識別子」がＡ１、Ａ２、Ａ３、Ｂ１、Ｃ１、Ｃ２で示される各部分ファイルの「所在地」と、「オリジナル所在地」が示されている。部分ファイル管理テーブル１７０２には、「部分ファイル識別子」がＣ１、Ｃ２、Ａ１で示される各部分ファイルの「所在地」と、「オリジナル所在地」が示されている。また、部分ファイル管理テーブル１７０３には、「部分ファイル識別子」がＡ２、Ａ３、Ｃ１で示される各部分ファイルの「所在地」と、「オリジナル所在地」が示されている。

【０１３３】ここで、図１７に示した部分ファイル管理テーブル１７０１、１７０２、１７０３の状態と図１６に示した部分ファイル管理テーブル１６０１、１６０２、１６０３の状態の差異は、部分ファイルＡ１（１２６ａ）を、サーバ計算機Ｃ１１０７からサーバ計算機Ｂ１１０６へ移動させたことと、部分ファイルＣ１（１２６ｅ）をサーバ計算機Ｂ１１０６からサーバ計算機Ｃ１１０７へ移動させたによるものである。

【０１３４】すなわち、部分ファイルＡ１（１２６ａ）の移動に対応して、部分ファイル管理テーブル１７０２には、部分ファイルＡ１（１２６ａ）の項目が追加されている。また、部分ファイル管理テーブル１７０３においては、部分ファイルＡ１（１２６ａ）の項目（図１６参照）が削除されている。さらに、サーバ計算機Ｂ１１０６が部分ファイルＡ１（１２６ａ）の「オリジナル所在地」を参照して、サーバ計算機Ａ１１０５に移動を知らせ、この通知によって、「オリジナル所在地」で示されるサーバ計算機Ａ１１０５においては、部分ファイル管理テーブル１７０１に登録されている部分ファイルＡ１（１２６ａ）の「所在地」を「ｆｉｌｅ：／／ｓｉｔｅＢ／ｓｅｒｖｅｒＢ／ＤｉｓｋＩＤ２／」に変更している。

【０１３５】また、部分ファイルＣ１（１２６ｅ）の移動に対応して、部分ファイル管理テーブル１７０２に登録されている部分ファイルＣ１（１２６ｅ）の「所在地」が、「ｆｉｌｅ：／／ｓｉｔｅＢ／ｓｅｒｖｅｒＢ／ＤｉｓｋＩＤ３／」（図１６（Ｂ））から、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ３／」に変更されている。また、部分ファイル管理テーブル１７０３においては、部分ファイルＣ１（１２６ｅ）の項目が追加されている。

【０１３６】次に、図１７に示す状態で、クライアント計算機１（１０８－１）が、分散ファイルＣを参照する際に、その参照内容が部分ファイルＣ１（１２６ｅ）に含まれる場合の動作を説明する。

【０１３７】（１）クライアント計算機１（１０８－１）は、分散ファイルＣを作成したサーバ計算機Ａ１１０５に対して、分散ファイルＣの参照を要求する。サーバ計算機Ａ１１０５では、分散ファイル管理テーブル１７０１を参照して、分散ファイルＣを構成する部分ファイルＣ１、Ｃ２のうちどの部分ファイルを参照しているのかを調べる。ここでは、部分ファイルＣ１（１２６ｅ）とする。部分ファイルＣ１（１２６ｅ）の「所在地」は、「ｆｉｌｅ：／／ｓｉｔｅＢ／ｓｅｒｖｅｒＢ／ＤｉｓｋＩＤ３／」なので、サーバ計算機Ａ１１０５は、サーバ計算機Ｂ１１０６に対して、部分ファイルＣ１（１２６ｅ）が存在するかどうかの確認を行なう。

【０１３８】（２）サーバ計算機Ｂ１１０６は、分散ファイル管理テーブル１７０２を調べて、部分ファイルＣ１（１２６ｅ）の「所在地」を調べる。部分ファイルＣ１（１２６ｅ）の「所在地」は、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ３／」なので、サーバ計算機Ｂ１１０６は、サーバ計算機Ｃ１１０７に対して、部分ファイルＣ１（１２６ｅ）が存在するかどうかの確認を行なう。

【０１３９】（３）サーバ計算機Ｃ１１０７は、分散ファイル管理テーブル１７０３を調べて、部分ファイルＣ１（１２６ｅ）の「所在地」を調べる。部分ファイルＣ１（１２６ｅ）の「所在地」は、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ３／」なので、部分ファイルＣ１（１２６ｅ）は、サーバ計算機Ｃ１１０７に存在することが解る。

【０１４０】（４）サーバ計算機Ｃ１１０７は、サーバ計算機Ｂ１１０６に、部分ファイルＣ１（１２６ｅ）は、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ３／」に存在することを通知する。

【０１４１】（５）この通知を受けて、サーバ計算機Ｂ１１０６は、サーバ計算機Ａ１１０５に、部分ファイルＣ１（１２６ｅ）が「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ３／」に存在することを通知する。

【０１４２】（６）サーバ計算機Ａ１１０５は、サーバ計算機Ｃ１１０７に部分ファイルＣ１（１２６ｅ）の参照を要求する。この要求と同時に、参照を要求したクライアント計算機１（１０８－１）に対して、サーバ計算機Ｃ１１０７に直接、部分ファイルＣ１（１２６ｅ）の

参照要求を行なうように指示する。また、サーバ計算機Ａ１１０５では、部分ファイルＣ１（１２６ｅ）の「所在地」を、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ３／」へと書き換える。

【０１４３】以上のように、本実施の形態では、分散ファイル管理部１１１２、１１１７、１１２２が、部分ファイル毎のアクセス情報テーブル１２０１、負荷情報テーブル４０１及び外部負荷情報テーブル９０１の各情報に基づいて、移動させる部分ファイルを決定する。また、他のサーバ計算機へ部分ファイルを移動する分散ファイル移動部１１３１、１１３２、１１３３を備えることにより、部分ファイルを他のサーバ計算機に移動することによって、特定のサーバ計算機の記憶装置への負荷の集中を回避できる。

【０１４４】なお、上述した第３の実施の形態では、分散ファイル移動部１１３１の動作アルゴリズム（図１５）のステップ１５０１において、記憶装置の各記憶部の「負荷」が所定の値を越えたことを検知する代わりに、記憶装置の各記憶部の「残容量」が所定の値、例えば、１０［Mbytes］などの値（ただし、この値は、装置やシステムの構成に応じて決定される）を下回ったことを検知するようにしてもよい。これによって、記憶装置の各記憶部の容量の不均衡を回避できる。

【０１４５】また、上述のステップ１５０１において、記憶装置の各記憶部の「負荷」が所定の値を越えたことを検知する代わりに、ネットワーク１０１の「負荷情報」から「使用通信帯域幅」が所定の値、例えば、使用可能通信帯域幅の８０［％］の値（ただし、この値は、装置やシステムの構成に応じて決定される）を越えたリンクを検知するようにすることもできる。また、ステップ１５０２において、アクセス情報テーブル１２０１からネットワーク１０１の負荷を高めている部分ファイルと、ネットワークの負荷を高めている計算機サイトを選択することによって、ネットワークの負荷の集中を回避することができる。例えば、計算機サイトＡ１１０２（送出元サイト）と計算機サイトＢ１１０３（送出先サイト）のリンクの「使用通信帯域幅」（図４）が所定の値を越えた時、サーバ計算機Ａ１１０５に存在し、ネットワーク負荷を高める原因となっている部分ファイルを、サーバ計算機Ｂ１１０３に移動する。これにより、計算機サイトＡ１１０２と計算機サイトＢ１１０３間の「使用通信帯域幅」を減少させることができる。

【０１４６】また、上述の第３の実施の形態では、ステップ１５０２において、移動先のサーバ計算機の部分ファイルを移動可能かを確認し、ステップ１５０３において、部分ファイルの移動を行なっているが、事前にステップ１５０２で部分ファイルの移動可能かを確認をすることなく部分ファイルを移動することによって、ステップ１５０２の確認処理を省略することができる。このとき、部分ファイルの移動先のサーバ計算機側で、部分ファイルの移動を受け入れられない場合には、移動先のサーバ計算機が、さらに部分ファイルを移動するための移動先を探し、この部分ファイルを移動するようにすればよい。

【０１４７】また、上述のステップ１５０３において、部分ファイルを移動元のサーバ計算機から、移動先のサーバ計算機へ移動しているが、その移動処理に加えて、移動先のサーバ計算機内の部分ファイルの中から移動元のサーバ計算機へ移動可能な他の部分ファイルを選択し、当該他の部分ファイルを移動元のサーバ計算機に移動するようにしてもよい。これによって、部分ファイルが１つのサーバ計算機に集中することを防ぐことができ、よりファイルアクセスに対する負荷を軽減することができる。

【０１４８】また、上述のステップ１５０２において、部分ファイルの移動先のサーバ計算機の選択を行なう際に、あらかじめサーバ計算機リストを設定し、リスト中のサーバ計算機の中から、記憶装置の各記憶部の残容量が十分あり、負荷が所定の値より低い記憶装置を持つサーバ計算機を選択するようにするとよい。これによって、部分ファイルの移動先のサーバ計算機の選択に費やされる時間を短縮することができる。

【０１４９】（実施の形態４）図１８は、図１１に示した分散ファイル管理システムの分散ファイル移動部１１３１、１１３２、１１３３の他の動作アルゴリズムを示すフローチャートである。

【０１５０】図１８において、まず、分散ファイル移動部１１３１、１１３２、１１３３は、各部分ファイルへの通信コストを所定の間隔で監視する（ステップ１８０１）。ここで、通信コストとしては、例えば、部分ファイルを参照しているクライアント計算機と、その部分ファイルを保持するサーバ計算機との間の通信時間とすることができる。図１１において、例えば、クライアント計算機１（１０８－１）と部分ファイルＡ２（１２６ｃ）の通信コストは、部分ファイルＡ２（１２６ｃ）を参照しているクライアント計算機１（１０８－１）と、部分ファイルＡ２（１２６ｃ）を保持するサーバ計算機Ｃ１１０７との間の通信時間とする。

【０１５１】ここで、分散ファイル移動部１１３１、１１３２、１１３３は、部分ファイルへの通信コストが所定の値、例えば、１秒など（ただし、この値は、装置やシステムの構成に応じて決定される）を越えたことを検知する（ステップ１８０１）と、通信コストが所定の値を越えた部分ファイルを移動元の部分ファイルとして選択する（ステップ１８０２）。また、この通信コストが所定の値を越えた部分ファイルに対して、複数のクライアント計算機がアクセスしている場合、各々のアクセスに対する通信コストを求め、これらを加算して合計通信コストを求める。

【０１５２】移動先のサーバ計算機を選択する際には、

外部負荷情報テーブル９０１に基づいて、記憶装置の各記憶部の「残容量」が十分にあり、それらに対する「負荷」が所定の値より低い記憶装置を持つサーバ計算機を選択する。そして、選択したサーバ計算機に対して、上述の合計通信コストを送信し、部分ファイルを移動した結果、通信コストがどのように変化するかを順に問い合わせ、最小の通信コストになるサーバ計算機を選択する（ステップ１８０２）。または、分散ファイル移動部１１３１、１１３２、１１３３が、サイト間の接続情報を持ち、その接続情報から通信コストを予想して、最小の通信コストになるサーバ計算機を選択するようにしてもよい（ステップ１８０２）。

【０１５３】図１９は、接続情報テーブルの一例を示す図である。図１９において、接続情報テーブル１９０１は、部分ファイルを送出する「送出元サイト」と、部分ファイルが送出される「送出先サイト」と、送出元サイトから送出先サイトまでの通信コストを示す「通信時間」の項目を有する。この接続情報テーブル１９０１から、部分ファイルを保持するサーバ計算機がどのサイトに属し、部分ファイルを参照するクライアント計算機がどのサイトに属すかにより、サーバ計算機とクライアント計算機の間の「通信時間」を得ることができる。この「通信時間」と上述した合計通信コストに基づいて、部分ファイルの移動後に「通信時間」が最小となるサーバ計算機を、部分ファイルの移動先として選択する（ステップ１８０２）。ここで、通信コストが所定の値を越えた部分ファイルに複数のクライアント計算機がアクセスしている場合には、部分ファイルの移動後の「通信時間」が最小の通信コストになるサーバ計算機を選択するようにするとよい。

【０１５４】例えば、クライアント計算機１（１０８－１）と部分ファイルＡ２（１２６ｃ）の通信コスト（以下、「コストＡ２」ともいう）が所定の値を越えたとき、部分ファイルＡ２（１２６ｃ）をサーバ計算機Ａ１１０５に移動した場合に、通信コストがどのようになるかをサーバ計算機Ａ１１０５に問い合わせるか、または、接続情報テーブル１９０１から通信コストを求める。その結果が、コストＡ２を下回っていれば、サーバ計算機Ａ１１０５を移動先サーバ計算機の候補にする。この処理を他のサーバ計算機に対しても行い、通信コストが最小になるサーバ計算機を探す（ステップ１８０２）。

【０１５５】最後に、この移動元部分ファイルの選択と移動先サーバ計算機の選択（ステップ１８０２）によって得られた情報に基づいて、部分ファイルの移動を行なう（ステップ１８０３）。

【０１５６】以上のように、第４の実施の形態では、分散ファイル移動部１１３１、１１３２、１１３３が、負荷情報テーブル４０１、外部負荷情報テーブル９０１及びアクセス情報テーブル１２０１の各情報と、接続情報テーブル１９０１から得られるサーバ計算機とクライアント計算機の間の接続情報とに基づいて、処理中の部分ファイルが存在するサーバ計算機と処理の要求元のクライアント計算機との間の通信コストを求め、通信コストが所定の値を超えた場合に、通信コストの小さくなる他のサーバ計算機へ部分ファイルを移動するようにしたので、上述した第３の実施の形態で得られる効果に加え、クライアント計算機から部分ファイルへのアクセス時間の平均値を短縮することができる。

【０１５７】なお、上述の第４の実施の形態では、通信コストとして、通信時間を例にあげているが、通信時間の「遅延」や「ゆらぎ（変動幅）」などにすることもできる。

【０１５８】また、上述の第４の実施の形態では、複数のクライアント計算機が同一の部分ファイルにアクセスしている場合、合計通信コストを最小にするように部分ファイルを移動しているが、平均通信コストを最小にするように部分ファイルを移動するようにしてもよい。

【０１５９】（実施の形態５）図２０は、本発明における分散ファイル管理システムの第５の実施の形態の一例を示す構成図である。この図２０においては、図８と同様の構成には同一の符号を付している。図２０に示した分散ファイル管理システムは、パーソナルコンピュータやワークステーションなどのサーバ計算機及びパーソナルコンピュータやワークステーションなどの複数のクライアント計算機から成るクライアント計算機群を備えた複数の計算機サイトＡ２００２、計算機サイトＢ２００３、及び計算機サイトＣ２００４と、計算機サイトＡ２００２、計算機サイトＢ２００３、及び計算機サイトＣ２００４を相互に接続するローカルエリアネットワークやワイドエリアネットワークなどのネットワーク１０１とを備えている。

【０１６０】ここで、計算機サイトＡ２００２は、パーソナルコンピュータやワークステーションなどの複数のサーバ計算機（図２０においては、「サーバ計算機Ａ２００５」のみ示す）と、パーソナルコンピュータやワークステーションなどのクライアント計算機１～ｎ（１０８－１～１０８－ｎ）から成るクライアント計算機群Ａ１０８とを備えている。この計算機サイトＡ２００２は、複数のサーバ計算機（図２０においては、「サーバ計算機Ａ２００５」のみ示す）とクライアント計算機群Ａ１０８とをイーサネットなどの内部ネットワーク１３１で接続しており、例えば、インターネットドメインになっている。

【０１６１】また、計算機サイトＡ２００２と同様に、計算機サイトＢ２００３は、複数のサーバ計算機（図２０においては、「サーバ計算機Ｂ２００６」のみ示す）と、複数のクライアント計算機から成るクライアント計算機群Ｂ１０９とを備え、計算機サイトＣ２００４は、複数のサーバ計算機（図２０においては、「サーバ計算

機Ｃ２００７」のみ示す）と、複数のクライアント計算機から成るクライアント計算機群Ｃ１１０とを備えている。さらに、これらの計算機サイトＢ２００３及び計算機サイトＣ２００４は、計算機サイトＡ２００２と同様に、複数のサーバ計算機（図２０においては、「サーバ計算機Ｂ２００６」及び「サーバ計算機Ｃ２００７」のみ示す）と、クライアント計算機群Ｂ１０９及びクライアント計算機群Ｃ１１０とを、それぞれ内部ネットワーク１３２及び内部ネットワーク１３３で接続しており、例えば、インターネットドメインになっている。

【０１６２】サーバ計算機Ａ２００５は、分散ファイルの部分ファイルを記録するハードディスクなどの記憶装置１１５と、イーサネットなどの内部ネットワーク１３１へ接続するためのネットワークインタフェース１１３と、部分ファイルを記録している記憶装置１１５への書き込みや読み出しを制御する部分ファイル管理部１１１と、記憶装置１１５に対する負荷や記憶装置１１５の残り容量、及びネットワークインタフェース１１３に対する負荷を監視し、これらの負荷や容量に関する情報を保持する状態管理部８１４と、部分ファイル管理部１１１、状態管理部８１４、及びネットワークインタフェース１１３に接続された分散ファイル管理部２０１２とによって構成されている。

【０１６３】この状態管理部８１４は、他のサーバ計算機へ負荷情報を通知し、また、他のサーバ計算機から通知された外部負荷情報を保持する外部状態管理部８１１を備えている。

【０１６４】また、分散ファイル管理部２０１２は、アクセス情報テーブル１２０１（図１２）、負荷情報テーブル４０１（図４）及び外部負荷情報テーブル９０１（図９）から得られる部分ファイル毎の各情報に基づいて、コピーする部分ファイルを決定し、他のサーバ計算機へ当該部分ファイルをコピーする分散ファイルコピー部２００１を備えている。

【０１６５】サーバ計算機Ｂ２００６及びサーバ計算機Ｃ２００７は、サーバ計算機Ａ２００５と同様の構成になっている。すなわち、サーバ計算機Ｂ２００６は、記憶装置１２０と、ネットワークインタフェース１１８と、部分ファイル管理部１１６と、外部状態管理部８１２を備えた状態管理部８１９と、分散ファイルコピー部２０３２を備えた分散ファイル管理部２０１７とによって構成されている。また、サーバ計算機Ｃ２００７は、記憶装置１２５と、ネットワークインタフェース１２３と、部分ファイル管理部１２１と、外部状態管理部８１３を備えた状態管理部８２４と、分散ファイルコピー部２０３３を備えた分散ファイル管理部２０２２とによって構成されている。

【０１６６】ここで、図２０に示した分散ファイル管理システムと図８に示した分散ファイル管理システムとの相違点は、図２０に示した分散ファイル管理部２０１２、２０１７、２０２２が、アクセス情報テーブル１２０１、負荷情報テーブル４０１及び外部負荷情報テーブル９０１から得られる部分ファイル毎の各情報に基づいて、コピーする部分ファイルを決定し、他のサーバ計算機へ当該部分ファイルをコピーする分散ファイルコピー部２０３１、２０３２、２０３３をを備えている点である。

【０１６７】以上のように構成された分散ファイル管理システムの動作について、分散ファイルＡ、分散ファイルＢ及び分散ファイルＣが、サーバ計算機Ａ２００５によって図２０に示すように作成された後に、部分ファイルのコピーを行なう場合を例にとって詳細に説明する。

【０１６８】図２１は、サーバ計算機Ａ２００５の分散ファイルコピー部２０３１の動作アルゴリズムを示すフローチャートである。図２１において、まず、分散ファイルコピー部２０３１は、状態管理部８１４が管理している負荷情報テーブル４０１（図４）を、所定の時間間隔で監視する（ステップ２１０１）。

【０１６９】分散ファイルコピー部２０３１は、記憶装置１１５の任意の記憶部の「負荷」が所定の値、例えば、８０［％］などの値を越えたことを検出する（ステップ２１０１）と、検出された記憶装置１１５の記憶部に含まれている部分ファイルを、部分ファイル管理テーブル１３０１（図１３）を参照して探し出す。そして探し出した部分ファイルのアクセス情報を、アクセス情報テーブル１２０１から獲得する。得られたアクセス情報の「アクセス回数」を比較し、最も大きな「アクセス回数」になっている部分ファイルを、コピー元部分ファイルとして選択する。ここで、例えば、部分ファイルＡ１（１２６ａ）が選択されたとする。次に、外部負荷情報テーブル９０１（図９）に基づいて、記憶装置の記憶部の「残容量」が十分あり、「負荷」が所定の値より低い記憶装置を持つサーバ計算機を選択する。そして、選択したサーバ計算機に対して、部分ファイルがコピーできるかどうかを確認し、コピー可能なサーバ計算機をコピー先サーバ計算機として選択する（ステップ２１０２）。

【０１７０】ここで、例えば、サーバ計算機Ｃ２００７の記憶装置１２５の記憶部（記憶装置識別子：ＤｉｓｋＩＤ２）が選択されたとする。

【０１７１】このコピー元部分ファイルの選択とコピー先サーバ計算機の選択によって得られた情報に基づいて、部分ファイルのコピーを行ない（ステップ２１０３）、再びステップ２１０１の監視処理を続行する。

【０１７２】ここで、上述の例の場合、ステップ２１０２で、コピー元部分ファイルとして部分ファイルＡ１（１２６ａ）、コピー先サーバ計算機としてサーバ計算機Ｃ２００７が選択されたので、コピー元のサーバ計算機Ａ２００５の分散ファイルコピー部２０３１は、部分ファイル管理部１１１を介して、記憶装置１１５から部

分ファイルＡ１（１２６ａ）を読み出し、この部分ファイルＡ１（１２６ａ）をネットワークインタフェース１１３を介してネットワーク１０１へ送出する。また、同時に部分ファイルＡ１（１２６ａ）の「オリジナル所在地」（図１３）に関する情報も送出する。

【０１７３】一方、コピー先のサーバ計算機Ｃ２００７では、分散ファイルコピー部２０３３が、コピー元のサーバ計算機Ａ２００５より送出された部分ファイルＡ１（１２６ａ）を、ネットワークインタフェース１２３を介して受信しする。そして、部分ファイル管理部１２１を介して、記憶装置１２５の所定の記憶部に書き込む。また、部分ファイルＡ１（１２６ａ）の「オリジナル所在地」も受信して、部分ファイル管理テーブル１４０３に登録する。その後、コピー先のサーバ計算機Ｃ２００７は、コピー元のサーバ計算機Ａ２００５と「オリジナル所在地」に示されているサーバ計算機（この例の場合には、「オリジナル所在地」もサーバ計算機Ａ２００５の記憶装置１１５の記憶部である）に対して、部分ファイルＡ１（１２６ａ）のコピーが完了したことを通知する。コピー元のサーバ計算機と「オリジナル所在地」に示されるサーバ計算機（両方ともサーバ計算機Ａ２００５）では部分ファイル管理テーブル１４０１の部分ファイルＡ１（１２６ａ）の情報を書き換える。

【０１７４】図２２は、コピー処理後のサーバ計算機の部分ファイル管理テーブルを示す図である。上述の部分ファイルＡ１（１２６ａ）のコピーの結果、図１４に示した部分ファイル管理テーブル１４０１、１４０２、１４０３は、図２２に示す部分ファイル管理テーブル２２０１、２２０２、２２０３の状態に変化する。すなわち、図２２（Ａ）は、サーバ計算機Ａ２００５の部分ファイル管理テーブル２２０１を示し、（Ｂ）は、サーバ計算機Ｂ２００６の部分ファイル管理テーブル２２０２を示し、（Ｃ）は、サーバ計算機Ｃ２００７の部分ファイル管理テーブル２２０３を示している。また、部分ファイル管理テーブル２２０１には、「部分ファイル識別子」がＡ１、Ａ２、Ａ３、Ｂ１、Ｃ１及びＣ２で示される各部分ファイルの「所在地」と、「オリジナル所在地」が示されている。また、部分ファイル管理テーブル２００２には、「部分ファイル識別子」がＣ１及びＣ２で示される各部分ファイルの「所在地」と、「オリジナル所在地」が示されている。また、部分ファイル管理テーブル２２０３には、「部分ファイル識別子」がＡ１、Ａ２及びＡ３で示される各部分ファイルの「所在地」と、「オリジナル所在地」が示されている。図１４に示した部分ファイル管理テーブルの状態と、図２２に示した部分ファイル管理テーブルの状態の差異は、部分ファイルＡ１（１２６ａ）を、サーバ計算機Ａ２００５からサーバ計算機Ｃ２００７へコピーしたことによる差異である。すなわち、図１４（Ａ）の部分ファイル管理テーブル１４０１において、部分ファイルＡ１（１２６ａ）の「所在地」が、「ｆｉｌｅ：／／ｓｉｔｅＡ／ｓｅｒｖｅｒＡ／ＤｉｓｉＩＤ１／」であるのに対して、図２２（Ａ）の部分ファイル管理テーブル２２０１においては、部分ファイルＡ１（１２６ａ）の「所在地」、が「ｆｉｌｅ：／／ｓｉｔｅＡ／ｓｅｒｖｅｒＡ／ＤｉｓｋＩＤ１／」及び「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ２／（コピーの所在地）」となっている点が相違する。さらに、図２２（Ｃ）の部分ファイル管理テーブル２１０３においては、部分ファイルＡ１（１２６ａ）の項目が追加されている。

【０１７５】また、図２２の状態から、サーバ計算機Ｂ２００６の分散ファイルコピー部２０３２が、部分ファイルＣ１（ｉ１２６ｅ）を、サーバ計算機Ｃ２００７にコピーし、サーバ計算機Ｃ２００７の分散ファイルコピー部２０３３が、部分ファイルＡ１（１２６ａ）を、サーバ計算機Ｂ２００６にコピーすることもできる。

【０１７６】図２３は、図２２の状態から、さらに部分ファイルをコピーした状態の部分ファイル管理テーブルを示す図である。図２３（Ａ）は、サーバ計算機Ａ２００５の部分ファイル管理テーブル２３０１を示し、（Ｂ）は、サーバ計算機Ｂ２００６の部分ファイル管理テーブル２３０２を示し、（Ｃ）は、サーバ計算機Ｃ２００７の部分ファイル管理テーブル２３０３を示している。図２３（Ａ）の部分ファイル管理テーブル２３０１には、「部分ファイル識別子」がＡ１、Ａ２、Ａ３、Ｂ１、Ｃ１及びＣ２の各部分ファイルの「所在地」と、「オリジナル所在地」が示されている。図２３（Ｂ）の部分ファイル管理テーブル２３０２には、「部分ファイル識別子」がＣ１、Ｃ２及びＡ１の各部分ファイルの「所在地」と、「オリジナル所在地」が示されている。また、図２３（Ｃ）の部分ファイル管理テーブル２３０３には、「部分ファイル識別子」がＡ１、Ａ２、Ａ３及びＣ１の各部分ファイルの「所在地」と、「オリジナル所在地」が示されている。図２２の部分ファイル管理テーブルの状態と図２３の部分ファイル管理テーブルの状態の差異は、部分ファイルＡ１（１２６ａ）を、サーバ計算機Ｃ２００７からサーバ計算機Ｂ２００６へコピーしたことと、部分ファイルＣ１（１２６ｅ）をサーバ計算機Ｂ２００６からサーバ計算機Ｃ２００７へコピーしたことによるものである。

【０１７７】すなわち、部分ファイルＡ１（１２６ａ）のコピーに対応して、部分ファイル管理テーブル２３０２において、部分ファイルＡ１（１２６ａ）の項目が追加されている。また、サーバ計算機Ｂ２００６が部分ファイルＡ１（１２６ａ）の「オリジナル所在地」を参照して、サーバ計算機Ａ２００５にコピーを知らせることで、「オリジナル所在地」のサーバ計算機Ａ２００５が、部分ファイル管理テーブル２３０１において、部分ファイルＡ１（１２６ａ）の「所在地」に、「ｆｉｌｅ：／／ｓｉｔｅＢ／ｓｅｒｖｅｒＢ／ＤｉｓｋＩＤ２

／」を追加している。また、部分ファイルＣ１（１２６ｅ）のコピーに対応して、部分ファイル管理テーブル２３０３において、部分ファイルＣ１（１２６ｅ）の項目が追加されている。さらに、部分ファイル管理テーブル２３０２において、部分ファイルＣ１（１２６ｅ）の「所在地」が、「ｆｉｌｅ：／／ｓｉｔｅＢ／ｓｅｒｖｅｒＢ／ＤｉｓｋＩＤ３／」および「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ３／（コピーの所在地）」となっている。

【０１７８】図２３に示す状態で、クライアント計算機１（１０８－１）が、分散ファイルＣを参照する際に、その参照内容が部分ファイルＣ１（１２６ｅ）に含まれる場合の動作を説明する。

【０１７９】（１）クライアント計算機１（１０８－１）は、分散ファイルＣを作成したサーバ計算機Ａ２００５に対して、分散ファイルＣの参照を要求する。サーバ計算機Ａ２００５では、分散ファイル管理テーブル２３０１を参照して、分散ファイルＣを構成する部分ファイルＣ１、Ｃ２のうちどの部分ファイルを参照しているのかを調べ、部分ファイルＣ１（１２６ｅ）の参照であることを認識する。部分ファイルＣ１（１２６ｅ）の「所在地」は、分散ファイル管理テーブル２３０１では「ｆｉｌｅ：／／ｓｉｔｅＢ／ｓｅｒｖｅｒＢ／ＤｉｓｋＩＤ３／」なので、サーバ計算機Ａ２００５は、サーバ計算機Ｂ２００６に対して、部分ファイルＣ１（１２６ｅ）が存在するかどうかの確認を行なう。

【０１８０】（２）サーバ計算機Ｂ２００６は、分散ファイル管理テーブル２３０２を調べて、部分ファイルＣ１（１２６ｅ）の所在地を調べる。部分ファイルＣ１（１２６ｅ）の「所在地」は、分散ファイル管理テーブル２３０２では「ｆｉｌｅ：／／ｓｉｔｅＢ／ｓｅｒｖｅｒＢ／ＤｉｓｋＩＤ３／」及び「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ３／」なので、サーバ計算機Ｂ２００６は、負荷情報テーブル４０１と外部負荷情報テーブル９０１からサーバ計算機Ｂ２００６とサーバ計算機Ｃ２００７のうち負荷の低いサーバ計算機を選択する。ここで、サーバ計算機Ｃ２００７を選択した場合、サーバ計算機Ｂ２００６は、サーバ計算機Ｃ２００７に対して、部分ファイルＣ１（１２６ｅ）が存在するかどうかの確認を行なう。

【０１８１】（３）サーバ計算機Ｃ２００７は、分散ファイル管理テーブル２３０３を調べて、部分ファイルＣ１（１２６ｅ）の「所在地」を確認する。部分ファイルＣ１（１２６ｅ）の「所在地」は、分散ファイル管理テーブル２３０３では「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ３／」なので、部分ファイルＣ１（１２６ｅ）は、サーバ計算機Ｃ２００７に存在することが解る。

【０１８２】（４）サーバ計算機Ｃ２００７は、サーバ計算機Ｂ２００６に、部分ファイルＣ１（１２６ｅ）が、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ３／」に存在することを通知する。

【０１８３】（５）サーバ計算機Ｂ２００６は、サーバ計算機Ａ２００５に、部分ファイルＣ１（１２６ｅ）が、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ３／」に存在することを通知する。

【０１８４】（６）サーバ計算機Ａ２００５は、サーバ計算機Ｃ２００７に部分ファイルＣ１（１２６ｅ）の参照を要求する。この要求と同時に、参照を要求したクライアント計算機１（１０８－１）に対して、クライアント計算機１（１０８－１）がサーバ計算機Ｃ２００７に直接に、部分ファイルＣ１（１２６ｅ）の参照要求を行なうように指示する。

【０１８５】以上のように、本実施の形態では、分散ファイル管理部１１２、１１７、１２２が、アクセス情報テーブル１２０１、負荷情報テーブル４０１及び外部負荷情報テーブル９０１から得られる部分ファイル毎の各情報に基づいて、コピーする部分ファイルを決定し、分散ファイルコピー部２０３１、２０３２、２０３３が、部分ファイルを他のサーバ計算機にコピーすることによって、特定のサーバ計算機の記憶装置への負荷の集中を回避することができる。

【０１８６】なお、上述した第５の実施の形態では、分散ファイルコピー部２０３１の動作アルゴリズム（図２１）のステップ２１０１において、記憶装置の各記憶部の「負荷」が所定の値を越えたことを検知するのに代えて、ネットワーク負荷情報テーブル４０３の「使用通信帯域幅」が所定の値を越えたリンクを検知することにしてもよい。また、ステップ２１０２において、アクセス情報テーブル１２０１からネットワーク負荷を高めている部分ファイルと、ネットワーク負荷を高めている計算機サイトを選択するようにしてもよい。これによって、ネットワーク負荷の集中を回避できる。例えば、計算機サイトＡ２００２（送出元サイト）と計算機サイトＢ２００３（送出先サイト）のリンクの「使用通信帯域幅」が所定の値を越えた時、サーバ計算機Ａ２００５に存在し、ネットワーク負荷を高める原因となっている部分ファイルをサーバ計算機Ｂ２００３にコピーする。これにより、計算機サイトＡ２００２と計算機サイトＢ２００３間の「使用通信帯域幅」が減少する。

【０１８７】図２４は、サーバ計算機Ａ２００５の分散ファイルコピー部２０３１の他の動作アルゴリズムを示すフローチャートである。図２４において、まず、分散ファイルコピー部２０３１は、部分ファイルへの通信コストを所定の間隔で監視する（ステップ２４０１）。

【０１８８】ここで、通信コストには、例えば、部分ファイルを参照しているクライアント計算機と、その部分ファイルを保持するサーバ計算機との間の通信時間とすることができる。例えば、クライアント計算機１（１０８－１）と部分ファイルＡ２（１２６ｃ）の通信コスト

の場合は、部分ファイルＡ２（１２６ｃ）を参照しているクライアント計算機１（１０８－１）と、部分ファイルＡ２（１２６ｃ）を保持するサーバ計算機Ｃ２００７の間の通信時間とすればよい。

【０１８９】次に、分散ファイルコピー部２０３１は、部分ファイルへの通信コストが所定の値を越えたことを検知した場合（ステップ２４０１）、この通信コストが所定の値を越えた部分ファイルを、コピー元部分ファイルとして選択する。通信コストが所定の値を越えた部分ファイルに、複数のクライアント計算機がアクセスしている場合には、各アクセス毎に各々の通信コストを求め、これらを加算して合計通信コストを求める。一方、コピー先のサーバ計算機を選択する際には、外部負荷情報テーブル９０１に基づいて、記憶装置の記憶部の「残容量」が十分あり、「負荷」が低い記憶装置を持つサーバ計算機を選択し、選択されたサーバ計算機に対して合計通信コストを送信し、部分ファイルをコピーした結果、通信コストがどのように変化するかを順に問い合わせる。そして、最小の通信コストになるサーバ計算機をコピー先サーバ計算機として選択する。または、分散ファイルコピー部２０３１、２０３２、２０３３が、サイト間（サーバ計算機とクライアント計算機との間）の接続情報として、例えば、図１９に示す接続情報テーブル１９０１を持ち、その情報から通信コスト（通信時間）を予想して、最小の通信コストになるサーバ計算機を選択するようにしてもよい。図１９の接続情報テーブル１９０１の情報と、サーバ計算機がどのサイトに属しクライアント計算機がどのサイトに属すかの情報とにより、サーバ計算機とクライアント計算機の間の「通信時間」を得ることができる。そして、その「通信時間」が最小となるサーバ計算機を、部分ファイルのコピー先として選択するとよい。通信コストが所定の値を越えた部分ファイルに、複数のクライアント計算機がアクセスしている場合には、最小の合計通信コストになるサーバ計算機をコピー先サーバ計算機として選択する（ステップ２４０２）。

【０１９０】例えば、クライアント計算機１（１０８－１）と部分ファイルＡ２の通信コスト（コストＡ２）が所定の値を越えた時には、部分ファイルＡ２をサーバ計算機Ａ１０５にコピーした場合に、通信コストがどのようになるかをサーバ計算機Ａ１０５に問い合わせる。あるいは、接続情報１８０１からコストを求める。その結果が、コストＡ２を下回っていれば、サーバ計算機Ａ１０５をコピー先の候補にする。この処理を繰り返して、通信コストが最小になるサーバ計算機を探す。このコピー元部分ファイルの選択とコピー先サーバ計算機の選択によって得られた情報に基づいて、部分ファイルのコピーを行ない（ステップ２４０３）、再びステップ２４０１の監視処理を続行する。

【０１９１】このように、図２１のステップ２１０１とステップ２１０２を図２４のステップ２４０１とステップ２４０２に変更することで、クライアント計算機から部分ファイルへのアクセス時間の平均値を短縮することができる。また、上記では通信コストとして、「通信時間」を例にあげているが、通信時間の「遅延」や「ゆらぎ（変動幅）」などでもよい。

【０１９２】また、図２１のステップ２１０２及び図２４のステップ２４０２において、コピー先のサーバ計算機に部分ファイルのコピーが可能かを確認し、ステップ２１０３及びステップ２４０３において、部分ファイルのコピーを行なっているが、ステップ２１０２及びステップ２４０２でサーバ計算機に部分ファイルのコピーが可能かを確認することなく、部分ファイルをコピーすることによって、ステップ２１０２及びステップ２４０２の確認処理を省略することができる。このとき、ステップ２１０３及びステップ２４０３において、コピー先のサーバ計算機側で、部分ファイルのコピーを受け入れられない場合には、コピー先のサーバ計算機は、さらに部分ファイルをコピーするためのコピー先を探して部分ファイルをコピーするか、あるいは、コピー用に送信されてきた部分ファイルを破棄して、コピー元のサーバ計算機にコピー用の部分ファイルを破棄したことを通知するようにしてもよい。

【０１９３】また、上述の第５の実施の形態では、図２１のステップ２１０３及び図２４のステップ２４０３において、部分ファイルをコピー元のサーバ計算機から、コピー先のサーバ計算機へ単にコピーしているが、そのコピー処理に加えて、コピー先のサーバ計算機内の部分ファイルの中からコピー元のサーバ計算機へ移動させても良い部分ファイルを選択し、その部分ファイルを移動元のサーバ計算機に移動するようにしてもよい。これによって、１つのサーバ計算機に部分ファイルが集中せず、特定のサーバ計算機の記憶装置への負荷の集中を回避することができる。

【０１９４】また、図２１のステップ２１０２において、コピー先のサーバ計算機の選択を行なう際に、あらかじめサーバ計算機リストを設定しておき、このサーバ計算機リスト中のサーバ計算機の中から、記憶装置の記憶部の残容量が十分あり、負荷が低い記憶装置を持つサーバ計算機を選択するようにすることもできる。これによって、サーバ選択のための時間を短縮することができるようになる。

【０１９５】（実施の形態６）図２５は、図２０に示した分散ファイル管理システムにおけるサーバ計算機Ａ２００５の分散ファイルコピー部２０３１の他の動作アルゴリズムを示すフローチャートである。本実施の形態においては、上述した第５の実施の形態と同様の構成となっており、分散ファイルコピー部の動作を除いては同様の動作を行う。以下、分散ファイルコピー部２０３１の動作アルゴリズムについて説明する。

【０１９６】図２５において、まず、分散ファイルコピー部２０３１は、状態管理部８１４が管理している負荷情報テーブル４０１（図４）を、所定の時間間隔で監視する（ステップ２５０１）。

【０１９７】分散ファイルコピー部２０３１は、記憶装置１１５の任意の記憶部の「負荷」が所定の値、例えば、８０［％］などの値を越えたことを検出する（ステップ２５０１）と、検出された記憶装置に含まれている部分ファイルを、部分ファイル管理テーブル１３０１（図１３）を参照して探し出す。そして、探し出した部分ファイルの「単位時間当たりのアクセス情報」を、アクセス情報テーブル１２０１から獲得する。獲得した「単位時間当たりのアクセス情報」の「アクセス回数」を比較し、最も大きな「アクセス回数」になっている部分ファイルを、コピー元部分ファイルとして選択する（ステップ２５０２）。ここでは、例えば、部分ファイルＡ１が選択されたとする。

【０１９８】次に、外部負荷情報テーブル９０１（図９）に基づいて、記憶装置の記憶部の「残容量」が十分あり、「負荷」が所定の値より低い記憶装置を持つ複数のサーバ計算機を選択する。そして、選択されたサーバ計算機に対して部分ファイルをコピーできるかどうかを確認し、コピー可能なサーバ計算機を、コピー先サーバ計算機として決定する（ステップ２５０２）。

【０１９９】ここで、例えば、サーバ計算機Ｂ１０６の記憶装置識別子ＤｉｓｋＩＤ１で示される記憶部を有する記憶装置１２０と、サーバ計算機Ｃ１０７の記憶装置識別子ＤｉｓｋＩＤ２で示される記憶部を有する記憶装置１２５が選択されたとする。

【０２００】次に、上述のステップ２５０２で得られたコピー元部分ファイルとコピー先サーバ計算機の情報に基づいて、部分ファイルのコピーを行ない（ステップ２５０３）、ステップ２５０１の監視処理を続行する。

【０２０１】上述の例において、ステップ２５０２で、コピー元部分ファイルとして部分ファイルＡ１（１２６ａ）、コピー先計算機としてサーバ計算機Ｂ２００６とサーバ計算機Ｃ２００７が選択されたので、コピー元のサーバ計算機Ａ２００５の分散ファイルコピー部２０３１は部分ファイル管理部１１１を介して、記憶装置１１５から部分ファイルＡ１（１２６ａ）を読み出し、ネットワークインタフェース１１３を介してネットワーク１０１へマルチキャストで送信する。また、同時に部分ファイルＡ１（１２６ａ）の「オリジナル所在地」（図１３）に関する情報も送信する。

【０２０２】一方、コピー先のサーバ計算機Ｂ２００６と計算機Ｃ２００７では、分散ファイルコピー部２０３２、２０３３がコピー元のサーバ計算機Ａ２００５より送信された部分ファイルＡ１（１２６ａ）を、ネットワークインタフェース１１８、１２３を介して受信し、部分ファイル管理部１１６、１２１を介して、記憶装置１２０、１２５に書き込む。また、部分ファイルＡ１（１２６ａ）の「オリジナル所在地」（図１３）も受信して、それぞれの部分ファイル管理テーブル１４０２、１４０３（図１４）に登録する。その後、コピー先のサーバ計算機Ｂ２００６とサーバ計算機Ｃ２００７は、それぞれコピー元のサーバ計算機と「オリジナル所在地」（図１３）に示されているサーバ計算機、すなわち、この場合には、両方ともサーバ計算機Ａ２００５であるため、両者ともこのサーバ計算機Ａ２００５に対して、部分ファイルＡ１（１２６ａ）のコピーが完了したことを通知する。コピー元のサーバ計算機と「オリジナル所在地」（図１３）に示されるサーバ計算機、すなわち、サーバ計算機Ａ２００５では部分ファイル管理テーブル１４０１（図１４）の部分ファイルＡ１（１２６ａ）の情報を書き換える。

【０２０３】以上のように、本実施の形態では、分散ファイルコピー部２０３１、２０３２、２０３３が部分ファイルを他のサーバ計算機へコピーする際に、複数のコピー先のサーバ計算機の候補を選択し、選択された複数のサーバ計算機へマルチキャスト通信により同時に部分ファイルをコピーするため、部分ファイルのコピーの際の通信量を削減できる。

【０２０４】（実施の形態７）図２６は、本発明における分散ファイル管理システムの他の実施の形態の一例を示す構成図である。ここで、図２６では、図１と同一の構成のものには同一の符号を付している。図２６において、この分散ファイル管理システムは、パーソナルコンピュータやワークステーションなどのサーバ計算機及びパーソナルコンピュータやワークステーションなどの複数のクライアント計算機から成るクライアント計算機群を備えた複数の計算機サイトＡ２６０２、計算機サイトＢ２６０３、及び計算機サイトＣ２６０４と、計算機サイトＡ２６０２、計算機サイトＢ２６０３、及び計算機サイトＣ２６０４を相互に接続するローカルエリアネットワークやワイドエリアネットワークなどのネットワーク１０１とを備えている。

【０２０５】ここで、計算機サイトＡ２６０２は、パーソナルコンピュータやワークステーションなどの複数のサーバ計算機（図２６においては、「サーバ計算機Ａ２６０５」のみ示す）と、パーソナルコンピュータやワークステーションなどのクライアント計算機１～ｎ（１０８－１～１０８－ｎ）から成るクライアント計算機群Ａ１０８とを備えている。この計算機サイトＡ２６０２は、複数のサーバ計算機（図２６においては、「サーバ計算機Ａ２６０５」のみ示す）とクライアント計算機群Ａ１０８とをイーサネットなどの内部ネットワーク１３１で接続しており、例えば、インターネットドメインになっている。

【０２０６】また、計算機サイトＡ２６０２と同様に、計算機サイトＢ２６０３は、複数のサーバ計算機（図２

６においては、「サーバ計算機Ｂ２６０６」のみ示す）と、複数のクライアント計算機から成るクライアント計算機群Ｂ２６０９とを備え、計算機サイトＣ２６０４は、複数のサーバ計算機（図２６においては、「サーバ計算機Ｃ２６０７」のみ示す）と、複数のクライアント計算機から成るクライアント計算機群Ｃ２６１０とを備えている。さらに、これらの計算機サイトＢ２６０３及び計算機サイトＣ２６０４は、計算機サイトＡ２６０２と同様に、複数のサーバ計算機（図２６においては、「サーバ計算機Ｂ２６０６」及び「サーバ計算機Ｃ２６０７」のみ示す）と、クライアント計算機群Ｂ１０９及びクライアント計算機群Ｃ１１０とを、それぞれ内部ネットワーク１３２及び内部ネットワーク１３３で接続しており、例えば、インターネットドメインになっている。

【０２０７】サーバ計算機Ａ２６０５は、分散ファイルの部分ファイルを記録するハードディスクなどの記憶装置１１５と、イーサネットなどの内部ネットワーク１３１へ接続するためのネットワークインタフェース１１３と、部分ファイルを記録している記憶装置１１５への書き込みや読み出しを制御する部分ファイル管理部１１１と、記憶装置１１５に対する負荷や記憶装置１１５の残り容量、及びネットワークインタフェース１１３に対する負荷を監視し、これらの負荷や容量に関する情報を保持する状態管理部１１４と、部分ファイル管理部１１１、状態管理部１１４、及びネットワークインタフェース１１３に接続された分散ファイル管理部２６１２とによって構成されている。

【０２０８】この分散ファイル管理部２６１２は、部分ファイルの書き込みや読み出しを部分ファイル管理部１１１に指示する。また、分散ファイル管理部２６１２は、分散ファイルを作成する場合には、状態管理部１１４から得られる情報に基づいて、分散ファイルを複数の部分ファイルに分割し、各部分ファイルを配置（記録）するサーバ計算機を決定する。また、以前に作成された分散ファイルを参照または更新する場合には、該当する分散ファイルの部分ファイルが存在する（記録されている）サーバ計算機を検出する。ここで、分散ファイル管理部２６１２は、クライアント計算機からの情報または分散ファイルに記録されるデータの種類に応じて、分散ファイルを部分ファイルへ分割する際の部分ファイルのサイズを決定する部分ファイルサイズ決定部２６３１を備えている。

【０２０９】サーバ計算機Ｂ２６０６及びサーバ計算機Ｃ２６０７は、サーバ計算機Ａ２６０５と同様の構成になっている。すなわち、サーバ計算機Ｂ２６０６は、記憶装置１２０と、ネットワークインタフェース１１８と、部分ファイル管理部１１６と、状態管理部１１９と、分散ファイル管理部２６１７とによって構成されている。また、サーバ計算機Ｃ２６０７は、記憶装置１２５と、ネットワークインタフェース１２３と、部分ファイル管理部１２１と、状態管理部１２４と、分散ファイル管理部２６２２とによって構成されている。また、分散ファイル管理部２６１７、２６２２は、それぞれ部分ファイルサイズ決定部２６３２、２６３３を備えている。

【０２１０】ここで、図２６に示した分散ファイル管理システムと図に示した分散ファイル管理システムとの相違点は、図２６の分散ファイル管理システムにおいて、分散ファイル管理部２６１２、２６１７、２６２２に、クライアント計算機からの情報または分散ファイルに記録されるデータの種類に応じて、分散ファイルを部分ファイルへ分割する際の部分ファイルのサイズを決定する部分ファイルサイズ決定部２６３１、２６３２、２６３３を備えている点である。

【０２１１】以上のように構成された分散ファイル管理システムの部分ファイルサイズ決定部２６３１、２６３２、２６３３の動作について以下に説明する。

【０２１２】図３において、例えば、クライアント計算機１（１０８－１）がサーバ計算機Ａ２６０５に対して、分散ファイルＡの作成要求を行なった時、ステップ３０２の処理で、分散ファイル管理部２６１２の部分ファイルサイズ決定部２６３１が、部分フィルを割り当てる時のサイズを決定する。部分ファイルサイズ決定部２６３１が、部分ファイルのサイズを決定するに際には、分散ファイルに記録するデータの種類（例えば、Ｍ－ＪＰＥＧ、ＭＰＥＧ１、ＭＰＥＧ２など）やクライアント計算機１（１０８－１）からの指示によって決めるようにするとよい。

【０２１３】以上のように、本実施の形態の分散ファイル管理システムにおいて、分散ファイル管理部２６１２、２６１７、２６２２の部分ファイルサイズ決定部２６３１、２６３２、２６３３が、クライアント計算機からの情報や分散ファイルに記録されるデータの種類などによって、分散ファイルを部分ファイルへ分割する際の部分ファイルのサイズを決定することにより、分散ファイルを構成する部分ファイルのサイズを適宜変更することができる。これにより、論理的や内容的に関連のあるデータ、例えば、画像１フレーム分のデータなどを複数の部分ファイルに分割してしまうことを防止することができる。

【０２１４】（実施の形態８）次に、上述した複数のサーバ計算機が有する分散ファイル管理部及び状態管理部を１つのサーバ計算機にまとめ、該サーバ計算機で集中して管理する場合について説明する。

【０２１５】図２７は、本発明における第１の実施の形態に示した分散ファイル管理システムにおいて、分散ファイル管理部及び状態管理部を１つのサーバ計算機にまとめた場合の分散管理システムの構成の一例を示している。図２７において、図１と同一の構成のものには同一

の符号を付している。

【０２１６】図２７に示した分散ファイル管理システムは、パーソナルコンピュータやワークステーションなどのサーバ計算機及びパーソナルコンピュータやワークステーションなどの複数のクライアント計算機から成るクライアント計算機群を備えた複数の計算機サイトＡ２７０２、計算機サイトＢ２７０３、及び計算機サイトＣ２７０４と、他のサーバ計算機上に配置されている分散ファイルを集中的に管理する管理サーバ計算機Ｘ２７１１を備えた計算機サイトＸ２７１０と、計算機サイトＡ２７０２、計算機サイトＢ２７０３、計算機サイトＣ２７０４、及び計算機サイトＸ２７１０を相互に接続するローカルエリアネットワークやワイドエリアネットワークなどのネットワーク１０１とを備えている。

【０２１７】ここで、計算機サイトＡ２７０２は、パーソナルコンピュータやワークステーションなどの複数のサーバ計算機（図２７においては、「サーバ計算機Ａ２７０５」のみ示す）と、パーソナルコンピュータやワークステーションなどのクライアント計算機１～ｎ（１０８－１～１０８－ｎ）から成るクライアント計算機群Ａ１０８とを備えている。この計算機サイトＡ２７０２は、複数のサーバ計算機（図２７においては、「サーバ計算機Ａ２７０５」のみ示す）とクライアント計算機群Ａ１０８とをイーサネットなどの内部ネットワーク１３１で接続しており、例えば、インターネットドメインになっている。

【０２１８】また、計算機サイトＡ２７０２と同様に、計算機サイトＢ２７０３は、複数のサーバ計算機（図２７においては、「サーバ計算機Ｂ２７０６」のみ示す）と、複数のクライアント計算機から成るクライアント計算機群Ｂ１０９とを備え、計算機サイトＣ２７０４は、複数のサーバ計算機（図２７においては、「サーバ計算機Ｃ２７０７」のみ示す）と、複数のクライアント計算機から成るクライアント計算機群Ｃ１１０とを備えている。さらに、これらの計算機サイトＢ２７０３及び計算機サイトＣ２７０４は、計算機サイトＡ２７０２と同様に、複数のサーバ計算機（図２７においては、「サーバ計算機Ｂ２７０６」及び「サーバ計算機Ｃ２７０７」のみ示す）と、クライアント計算機群Ｂ１０９及びクライアント計算機群Ｃ１１０とを、それぞれ内部ネットワーク１３２及び内部ネットワーク１３３で接続しており、例えば、インターネットドメインになっている。

【０２１９】サーバ計算機Ａ２７０５は、分散ファイルの部分ファイルを記録するハードディスクなどの記憶装置１１５と、イーサネットなどの内部ネットワーク１３１へ接続するためのネットワークインタフェース１１３と、部分ファイルを記録している記憶装置１１５への書き込みや読み出しを制御する部分ファイル管理部１１１とによって構成されている。

【０２２０】サーバ計算機Ｂ２７０６及びサーバ計算機Ｃ２７０７は、サーバ計算機Ａ２７０５と同様の構成になっている。すなわち、サーバ計算機Ｂ２７０６は、記憶装置１２０と、ネットワークインタフェース１１８と、部分ファイル管理部１１６とによって構成されている。また、サーバ計算機Ｃ２７０７は、記憶装置１２５と、ネットワークインタフェース１２３と、部分ファイル管理部１２１とによって構成されている。

【０２２１】管理サーバ計算機Ｘ２７１１は、イーサネットなどの内部ネットワーク１３４に接続するためのネットワークインタフェース２７１３と、各サーバ計算機の記憶装置の負荷や残り容量、ネットワークインタフェースの負荷を監視し、負荷に関する情報を保持する状態管理部２７１４と、部分ファイルの書き込みや読み出しを各サーバ計算機の部分ファイル管理部１１１、１１６、１２１に指示したり、分散ファイルを作成する際に、状態管理部２７１４からの情報に基づいて分散ファイルを複数の部分ファイルに分割し、各部分ファイルを配置するサーバ計算機を決定することによって部分ファイルの作成を行ない、また、分散ファイルを参照または更新する場合には、参照または更新される当該分散ファイルの部分ファイルが在左するサーバ計算機を検出して部分ファイルの参照または更新を行なう分散ファイル管理部２７１２によって構成されている。

【０２２２】図２７においては、各分散ファイルＡ、Ｂ、Ｃが作成された後の状態を示している。すなわち、サーバ計算機Ａ２７０５の記憶装置１１５には、分散ファイルＡの部分ファイルＡ１（１２６ａ）と分散ファイルＢの部分ファイルＢ１（１２６ｂ）とが記録されている。また、サーバ計算機Ｂ２７０６の記憶装置１２０には、分散ファイルＣの部分ファイルＣ１（１２６ｅ）と分散ファイルＣの部分ファイルＣ２（１２６ｆ）とが記録されている。また、サーバ計算機Ｃ２７０７の記憶装置１２５には、分散ファイルＡの部分ファイルＡ２（１２６ｃ）と分散ファイルＡの部分ファイルＡ３（１２６ｄ）とが記録されている。

【０２２３】次に、以上のように構成された分散ファイル管理システムの動作について説明する。以下においては、クライアント計算機群Ａ１０８のクライアント計算機１（１０８－１）からサーバ計算機Ａ２７０５に対して分散ファイルＡの作成要求が発行され、図２７に示したような部分ファイルＡ１～Ａ３が作成される場合の分散処理を例にして説明する。ここで、図２７に示した記憶装置１１５、１２０、１２５は、それぞれ複数の記憶部または記憶領域（以下、単に「記憶部」ともいう）を有するものとする。これらの複数の記憶部は、物理的に１つの記録媒体であってもよく、また、複数の記録媒体であってもよい。

【０２２４】図２７において、まず、クライアント計算機１（１０８－１）から計算機サイトＸ２７１０の管理サーバ計算機Ｘ２７１１に分散ファイルＡの作成要求が

発行される。この分散ファイルＡの作成要求は、計算機サイトＡ２７０２の内部ネットワーク１３１、ネットワーク１０１、計算機サイトＸ２７１０の内部ネットワーク１３４、及び管理サーバ計算機Ａ２７１１のネットワークインタフェース２７１３を介して、分散ファイル管理部２７１２によって受け取られる。

【０２２５】図２８は、分散ファイルの作成要求を受け取った場合の分散ファイル管理部２７１２の動作アルゴリズムを示すフローチャートである。以下、図２７及び図２８を用いて、分散ファイル管理部２７１２の詳細な動作を説明する。

【０２２６】図２８において、まず、分散ファイル管理部２７１２は、状態管理部２７１４の管理している負荷情報を参照する（ステップ２８０１）。

【０２２７】状態管理部２７１４では、例えば、図４のような負荷情報テーブル４０１を管理している。図４では、サーバ計算機Ａ２７０５に関する情報について示しているが、状態管理部２７１４では、図４に示したような負荷情報テーブル４０１を各サーバ計算機毎に準備し管理してる。図４において、負荷情報テーブル４０１は、記憶装置負荷情報テーブル４０２とネットワーク負荷情報テーブル４０３からなる。記憶装置負荷情報テーブル４０２は、サーバ計算機に接続されている記憶装置の各記憶部を識別するための「記憶装置識別子」と、記憶装置の各記憶部の「負荷」と、記憶装置の各記憶部の「残容量」の情報で構成されている。記憶装置の各記憶部の「負荷」は、記憶部の最大転送レートのうち、何［％］を使用しているかで表示している。ネットワーク負荷情報テーブル４０３は、それぞれのサーバ計算機のネットワークインタフェースを介して送信するデータがどのサイトに向けてのものであり、どの程度の帯域幅を使用して送信されているか、また、受信しているテータがどのサイトから送られて来たものであり、どの程度の帯域幅を使用して受信しているかを表している。また、「送出元サイト」がデータの送出元の計算機サイトを示し、「送出先サイト」がデータの送出先の計算機サイトを示し、「使用帯域幅」が送出元の計算機サイトと送出先の計算機サイトの間で使用されている通信帯域幅を示している。

【０２２８】例えば、分散ファイルＡを作成する場合、分散ファイル管理部２７１２は、サーバ計算機Ａ２７０５の記憶装置１１５の記憶装置識別子がＤｉｓｋＩＤ１で示される記憶部について、その「負荷」が２０［％］で、その「残容量」が１０［Mbytes］であるという情報を得ることができる。

【０２２９】次に、分散ファイル管理部２７１２は、状態管理部２７１４から得られた「記憶装置負荷情報」に基づいて、各サーバ計算機に接続されている記憶装置の各記憶部の中から、「残容量」の値が所定の値より大きく、「負荷」の値が所定の値、例えば、８０［％］（この値は、システムや他の装置の構成に応じて決定される）より低い記憶部を有する記憶装置を選択する。そして、この記憶装置の記憶部に部分ファイルを順番に割り当てる。このとき、部分ファイルのサイズを全てのサーバ計算機で同一の固定長とするとよい。この部分ファイルの割り当て処理において、全ての部分ファイルを割り当てることができたかどうかを検知する（ステップ２８０２）。

【０２３０】ここで、分散ファイルＡを作成する場合、図２７においては、部分ファイルＡ１（１２６ａ）をサーバ計算機Ａ２７０５に割り当て、部分ファイルＡ２（１２６ｃ）及び部分ファイルＡ３（１２６ｄ）をサーバ計算機Ｃ２７０４に割り当てることになる。

【０２３１】全ての部分ファイルを割り当てることができた場合には、分散ファイル管理部２７１２は、分散ファイルを管理するための情報を、例えば、上述したような図５の分散ファイル管理テーブル５０１と図６の部分ファイル管理テーブル６０１に登録する（ステップ２８０３）。

【０２３２】上述の例においては、図５に示すように、分散ファイルＡは、部分ファイルＡ１（１２６ａ）、部分ファイルＡ２（１２６ｃ）、及び部分ファイルＡ３（１２６ｄ）から構成されている。

【０２３３】また、図６において、部分ファイルＡ１（１２６ａ）の所在地が、「ｆｉｌｅ：／／ｓｉｔｅＡ／ｓｅｒｖｅｒＡ／ＤｉｓｋＩＤ１／（計算機サイトＡ１０２のサーバ計算機Ａ１０５の記憶装置識別子ＤｉｓｋＩＤ１）」であり、部分ファイルＡ２（１２６ｃ）の所在地が、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ２／（計算機サイトＣ１０４のサーバ計算機Ｃ１０７の記憶装置識別子ＤｉｓｋＩＤ２）」であり、部分ファイルＡ３（１２６ｄ）の所在地が、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ２／（計算機サイトＣ１０４のサーバＣ１０７の記憶装置ＤｉｓｋＩＤ２）」であることを表している。

【０２３４】次に、分散ファイル管理部２７１２は、ステップ２８０３で登録した部分ファイルを該当する各サーバ計算機上に作成するため、作成を行なうサーバ計算機の部分ファイル管理部に部分ファイルの作成要求を行う。この作成要求と同時に、分散ファイルの作成要求を行なったクライアント計算機１（１０８－１）に対して、クライアント計算機１（１０８－１）から直接部分ファイルの作成を行なうサーバ計算機にデータを送信するように指示する。部分ファイルの作成を要求されたサーバ計算機では、部分ファイル管理部によって記憶装置の各記憶部にクライアント計算機１（１０８－１）からのデータの書き込みを行なう。分散ファイル管理部２７１２は、全ての部分ファイルの作成が終るまでこの処理を繰り返す（ステップ２８０４）。

【０２３５】ここで、分散ファイルＡの部分ファイルＡ

１（１２６ａ）の作成の場合、サーバ計算機Ａ２７０５の部分ファイル管理部１１１が、クライアント計算機１（１０８－１）からのデータを記憶装置１１５の所定の記憶部に書き込む。また、サーバ計算機Ｃ２７０７の部分ファイル管理部１２１は、クライアント計算機１（１０８－１）からのデータを記憶装置１２５の所定の記憶部に書き込んで、部分ファイルＡ２（１２６ｃ）及び部分ファイルＡ３（１２６ｄ）を作成する。

【０２３６】一方、ステップ２８０２で、全ての部分ファイルを割り当てることができなかった場合には、分散ファイル管理部２７１２は、分散ファイルの作成要求を行なったクライアント計算機１（１０８－１）に対して、分散ファイルの作成処理が失敗したことを通知する（ステップ２８０５）。

【０２３７】次に、クライアント計算機から管理サーバ計算機に対して分散ファイルの参照または更新の要求（以下、「参照／更新要求」ともいう）が発行された場合について説明する。また、以下の説明において、クライアント計算機群Ａ１０８内のクライアント計算機１（１０８－１）から管理サーバ計算機Ｘ２７１１に対して分散ファイルＡの参照／更新要求が発行された場合を例にして述べる。

【０２３８】まず、クライアント計算機１（１０８－１）によって発行された分散ファイルＡに対する参照／更新要求は、管理サーバ計算機Ｘ２７１１において、ネットワークインタフェース２７１３を介して、分散ファイル管理部２７１２によって受信される。

【０２３９】図２９は、分散ファイル管理部が分散ファイルの参照／更新要求を受け取った場合の動作アルゴリズムを示すフローチャートである。以下、図２９を用いて、分散ファイル管理部２７１２の動作を説明する。

【０２４０】まず、分散ファイル管理部２７１２は、クライアント計算機１（１０８－１）からの分散ファイルＡの参照／更新要求に応じて、分散ファイル管理テーブル５０１（図５）と部分ファイル管理テーブル６０１（図６）から、更新または参照する部分ファイルと、その部分ファイルの所在地を求める（ステップ２９０１）。

【０２４１】ここで、分散ファイルＡの参照／更新要求の場合、分散ファイル管理テーブル５０１（図５）から、分散ファイルＡは、部分ファイルＡ１（１２６ａ）、部分ファイルＡ２（１２６ｃ）及び部分ファイルＡ３（１２６ｄ）により構成されていることがわかる。また、部分ファイル管理テーブル６０１（図６）によって、部分ファイルＡ１（１２６ａ）は、「ｆｉｌｅ：／／ｓｉｔｅＡ／ｓｅｒｖｅｒＡ／ＤｉｓｋＩＤ１／」で示される記憶装置１１５の記憶部に存在し、部分ファイルＡ２（１２６ｃ）は、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ２／」で示される記憶装置１２５の記憶部に存在し、部分ファイルＡ３（１２６ｄ）は、「ｆｉｌｅ：／／ｓｉｔｅＣ／ｓｅｒｖｅｒＣ／ＤｉｓｋＩＤ２／」で示される記憶装置１２５の記憶部に存在することが解る。

【０２４２】分散ファイル管理部２７１２は、クライアント計算機１（１０８－１）からの参照／更新要求に対応する部分ファイルを保持するサーバ計算機に対して、当該部分ファイルの参照／更新要求を行う。この要求と同時に、分散ファイル管理部２７１２は、クライアント計算機１（１０８－１）に対して、クライアント計算機１（１０８－１）が参照または更新を行う部分ファイルの存在するサーバ計算機に直接、参照／更新要求を行うように指示する。各サーバ計算機の部分ファイル管理部は、分散ファイル管理部２７１２からの要求に応じ、クライアント計算機１（１０８－１）からの参照／更新要求に基づいて、記憶装置に存在する部分ファイルの読み出し（参照）、または記憶装置への部分ファイルの書き込み（更新）を行なう（ステップ２９０２）。

【０２４３】ここで、分散ファイルＡの場合、部分ファイルＡ１（１２６ａ）は、計算機サイトＡ２７０２のサーバ計算機Ａ２７０５に、部分ファイルＡ２（１２６ｃ）は、計算機サイトＣ２７０４のサーバ計算機Ｃ２７０７に、部分ファイルＡ３（１２６ｄ）は、計算機サイトＣ２７０４のサーバ計算機Ｃ２７０７に存在している。したがって、部分ファイルＡ１（１２６ａ）に対する参照／更新要求の処理は、分散ファイル管理部２７１２からの要求に応じて、クライアント計算機１（１０８－１）と部分ファイル管理部１１１との間で直接行なわれる。一方、部分ファイルＡ２（１２６ｃ）と部分ファイルＡ３（１２６ｄ）に対する参照／更新要求の処理は、分散ファイル管理部２７１２からの要求に応じて、クライアント計算機１（１０８－１）と、サーバ計算機Ｃ２７０７との間で直接行なわれる。

【０２４４】以上のように、本実施の形態の分散ファイル管理システムによれば、第１の実施の形態に示した効果に加え、分散ファイルの管理とシステムの状態の管理を集中して行うため、重複した管理部を複数持つ必要がなく、システム構成を簡略することができ、またコストの軽減を図ることができる。

【０２４５】尚、上述した図２７の分散ファイル管理システムにおいては、第１の実施の形態で示した分散ファイル管理システムの管理部を、１つの管理サーバ計算機に集中した構成として説明したが、第２～第７で示した実施の形態の分散ファイル管理システムにも適用することができる。

【０２４６】また、上述した図２７の分散ファイル管理システムにおいて、分散ファイル管理システムの管理部を、１つの管理サーバ計算機に集中した構成として説明したが、所定のグループのサーバ計算機毎や所定のグループの計算機サイト毎に管理サーバ計算機を設けるようにしてもよい。このようにすると、大規模なシステムに

おける管理サーバ計算機への負荷の集中を防止することができる。

【０２４７】また、上述した実施の形態において、部分ファイルが複数のサーバ計第機上に存在する場合の部分ファイルの選択においては、単にサーバ計算機の「負荷」の小さい順に選択するだけでなく、サーバ計算機を所定の規則に基づいて順番に使用するようにしてもよく、また、所定の閾値以下の「負荷」を有するサーバ計算機をランダムに選択するようにしてもよい。

【０２４８】

【発明の効果】以上のように、本発明の分散ファイル管理装置及び分散ファイル管理システムによれば、クライアント計算機からサーバ計算機に対する分散ファイルの作成、参照、または更新の要求に応じて、要求されたサーバ計算機または管理サーバ計算機の各々の管理部で、各サーバ計算機の負荷情報に基づいて部分ファイルの配置を決定するため、特定のサーバ計算機への負荷の集中を回避することができるようになった。

【０２４９】また、他のサーバ計算機へ負荷情報を通知し、また、他のサーバ計算機から通知された外部負荷情報を保持して、他のサーバ計算機の負荷情報に基づいて、部分ファイルの配置を決定するため、特定のサーバ計算機への負荷の集中を回避することができるようになった。

【０２５０】また、部分ファイル毎のアクセス情報、負荷情報及び外部負荷情報に基づいて、移動させる部分ファイルを決定し、他のサーバ計算機へ部分ファイルを移動するため、特定のサーバ計算機の記憶装置への負荷の集中や、各サーバ計算機の記憶装置の容量の不均衡を回避することができるようになった。

【０２５１】また、部分ファイル毎のアクセス状況、負荷情報及び外部負荷情報に基づいて、コピーする部分ファイルを決定し、他のサーバ計算機に部分ファイルをコピーするため、特定のサーバ計算機の記憶装置への負荷の集中を回避することができるようになった。

【０２５２】また、クライアント計算機からの情報や分散ファイルに記録されるデータの種類によって、分散ファイルを分割して作成する部分ファイルのサイズを決定するため、分散ファイルを構成する部分ファイルのサイズを適宜変更することができ、内容的、論理的に関連のあるデータ、例えば、画像１フレーム分のデータなどを複数の部分ファイルに分けて記録することを防止することができるようになった。

【０２５３】また、分散ファイルの部分ファイルを管理する各管理部を１つまたは複数の管理用サーバ計算機に集中させることにより、リソースの重複を最小限に抑えることができるため、コストの増加を抑えることができるようになった。

【図面の簡単な説明】

【図１】本発明の分散ファイル管理システムを示すブロック図である。

【図２】本発明における分散ファイルの構成を示す図である。

【図３】本発明の分散ファイル管理部の分散ファイル作成アルゴリズムを示すフローチャートである。

【図４】本発明における負荷情報テーブルの一例を示す図である。

【図５】本発明の分散ファイル管理テーブルの一例を示す図である。

【図６】本発明の部分ファイル管理テーブルの一例を示す図である。

【図７】本発明の分散ファイル管理部の分散ファイルの参照／更新アルゴリズムを示すフローチャートである。

【図８】本発明の分散ファイル管理システムを示すブロック図である。

【図９】本発明における外部負荷情報テーブルの一例を示す図である。

【図１０】本発明における分散ファイル管理部の分散ファイル作成アルゴリズムを示すフローチャートである。

【図１１】本発明の分散ファイル管理システムを示すブロック図である。

【図１２】本発明における部分ファイルアクセス情報テーブルの一例を示す図である。

【図１３】本発明における部分ファイル管理テーブルの一例を示す図である。

【図１４】本発明における部分ファイル管理テーブルの一例を示す図である。

【図１５】本発明における分散ファイル移動部の動作アルゴリズムを示すフローチャートである。

【図１６】本発明における部分ファイル管理テーブルの一例を示す図である。

【図１７】本発明における部分ファイル管理テーブルの一例を示す図である。

【図１８】本発明における分散ファイル移動部の動作アルゴリズムを示すフローチャートである。

【図１９】本発明における接続情報テーブルの一例を示す図である。

【図２０】本発明の分散ファイル管理システムを示すブロック図である。

【図２１】本発明における分散ファイルコピー部の動作アルゴリズムを示すフローチャートである。

【図２２】本発明における部分ファイル管理テーブルの一例を示す図である。

【図２３】本発明における部分ファイル管理テーブルの一例を示す図である。

【図２４】本発明における分散ファイルコピー部の動作アルゴリズムを示すフローチャートである。

【図２５】本発明における分散ファイルコピー部の動作アルゴリズムを示すフローチャートである。

【図２６】本発明の分散ファイル管理システムを示すブ

ロック図である。
【図２７】本発明の分散ファイル管理システムを示すブロック図である。
【図２８】本発明の分散ファイル管理部の分散ファイル作成アルゴリズムを示すフローチャートである。
【図２９】本発明の分散ファイル管理部の分散ファイルの参照／更新アルゴリズムを示すフローチャートである。
【図３０】従来の分散ファイル管理装置を示すブロック図である。
【符号の説明】
１０１　ネットワーク
１０２～１０４、８０２～８０４、１１０２～１１０４、２００２～２００４、２６０２～２６０４、２７０２～２７０４、２７１０　計算機サイト
１０５～１０７、８０５～８０７、１１０５～１１０７、２００５～２００７、２６０５～２６０７、２７０５～２７０７　サーバ計算機
１０８、１０９、１１０　クライアント計算機群
１０８－１～１０８－ｎ　クライアント計算機
１１１、１１６、１２１　部分ファイル管理部
１１２、１１７、１２２、１１１２、１１１７、１１２２、２０１２、２０１７、２０２２、２６１２、２６１７、２６２２、２７１２　分散ファイル管理部
１１３、１１８、１２３、２７１３　ネットワークインタフェース
１１４、１１９、１２４、８１４、８１９、８２４、２７１４　状態管理部
１１５、１２０、１２５　記憶装置
１２６ａ～１２６ｆ、２０２－１～２０２－ｎ　部分ファイル
１３１～１３３　内部ネットワーク
４０１　負荷情報テーブル
４０２　記憶装置負荷情報テーブル
４０３　ネットワーク負荷情報テーブル
５０１　分散ファイル管理テーブル
６０１、１３０１、１４０１～１４０３、１６０１～１６０３、１７０１～１７０３、２２０１～２２０３、２３０１～２３０３　部分ファイル管理テーブル
８１１、８１２、８１３　外部状態管理部
９０１　外部負荷情報テーブル
１１３１、１１３２、１１３３　分散ファイル移動部
１２０１　アクセス情報テーブル
１９０１　接続情報テーブル
２０３１、２０３２、２０３３　分散ファイルコピー部
２６３１、２６３２、２６３３　部分ファイルサイズ決定部
２７１１　管理サーバ計算機

【図２】

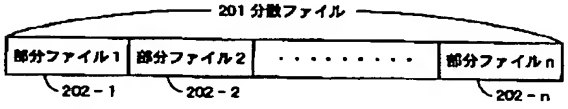

【図４】

402

記憶装置負荷情報		
記憶装置識別子	負荷	残容量
Disk ID 1	20 %	10 Mbytes
Disk ID 2	30 %	200 Mbytes
⋮	⋮	⋮
⋮	⋮	⋮

401

403

ネットワーク負荷情報		
リンク		使用通信帯域幅
送出元サイト	送出先サイト	
site A	site B	30 Mbps
site A	site C	50 Mbps
⋮	⋮	⋮
⋮	⋮	⋮

【図５】

501

分散ファイル識別子	部分ファイル識別子リスト
A	A1, A2, A3
B	B1
C	C1, C2
⋮	⋮
⋮	⋮

【図６】

601

部分ファイル識別子	所在地
A1	file://site A/server A/Disk ID 1/
A2	file://site C/server C/Disk ID 2/
A3	file://site C/server C/Disk ID 2/
B1	file://site A/server A/Disk ID 1/
C1	file://site B/server B/Disk ID 3/
C2	file://site B/server B/Disk ID 3/
⋮	⋮
⋮	⋮

【図９】

901

サーバ計算機所在地	記憶装置負荷情報		
	記憶装置識別子	負荷	残容量
site B/server B	Disk ID 1	49 %	1000 Mbytes
site C/server C	Disk ID 1	30 %	3000 Mbytes
⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮

【図１】

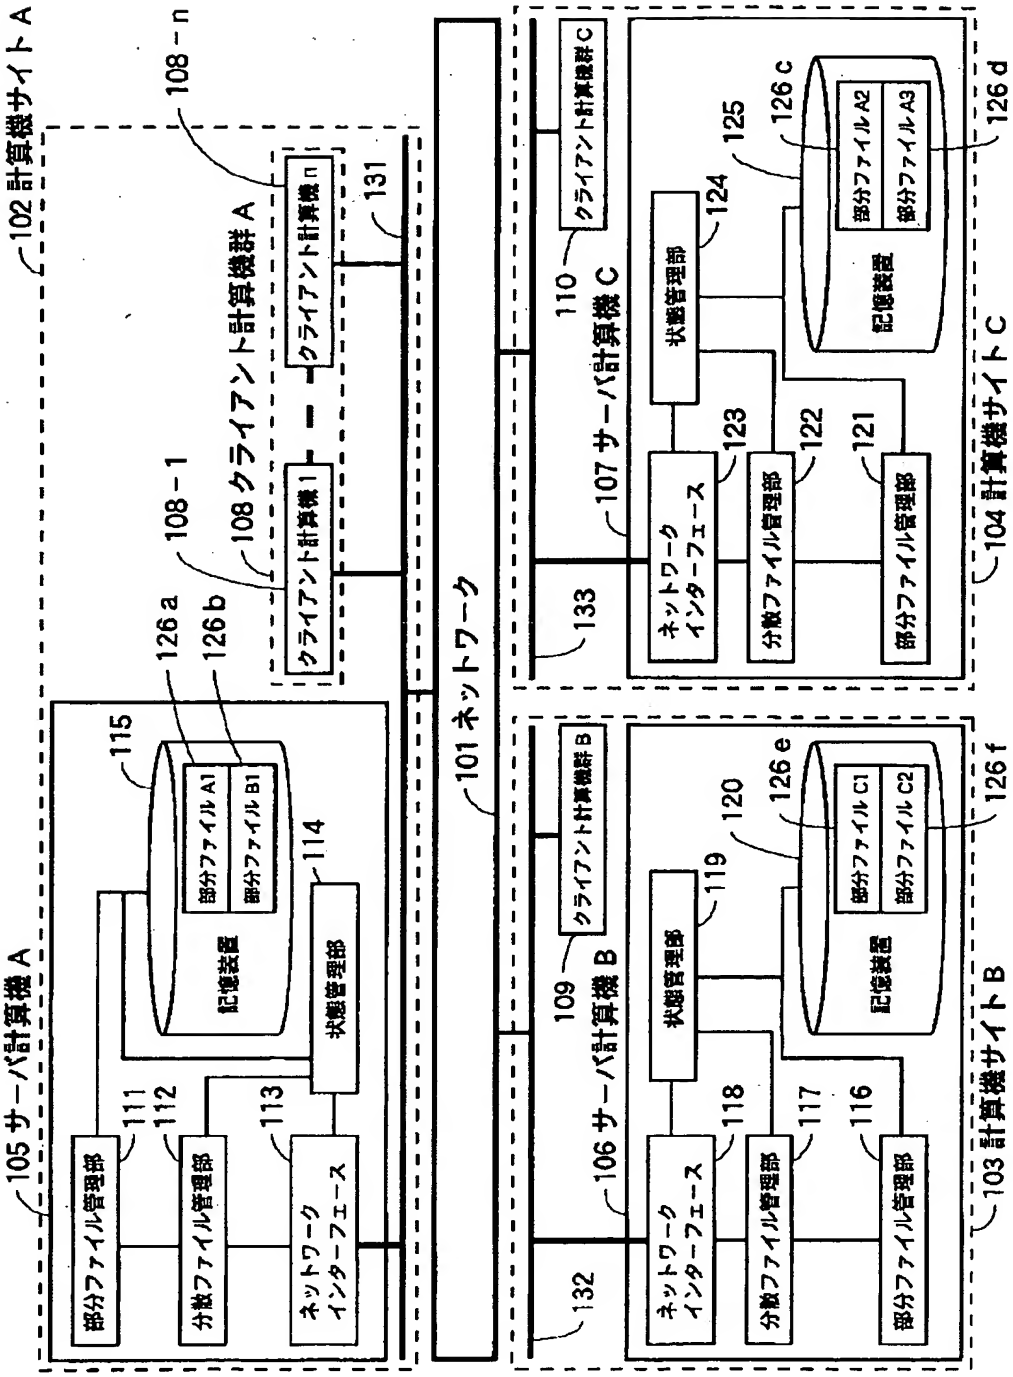
102 計算機サイト A
105 サーバ計算機 A
108－n
108－1
108 クライアント計算機群 A
クライアント計算機 1
クライアント計算機 n
131
126 a
126 b
115
部分ファイル A1
部分ファイル B1
記憶装置
114
状態管理部
111
112
113
部分ファイル管理部
分散ファイル管理部
ネットワーク インターフェース
101 ネットワーク
110
クライアント計算機群 C
107 サーバ計算機 C
133
124
125
126 c
状態管理部
ネットワーク インターフェース
分散ファイル管理部
部分ファイル管理部
123
122
121
部分ファイル A2
部分ファイル A3
記憶装置
104 計算機サイト C
126 d
109
クライアント計算機群 B
106 サーバ計算機 B
132
119
120
126 e
状態管理部
ネットワーク インターフェース
分散ファイル管理部
部分ファイル管理部
118
117
116
部分ファイル C1
部分ファイル C2
記憶装置
103 計算機サイト B
126 f

【図３】

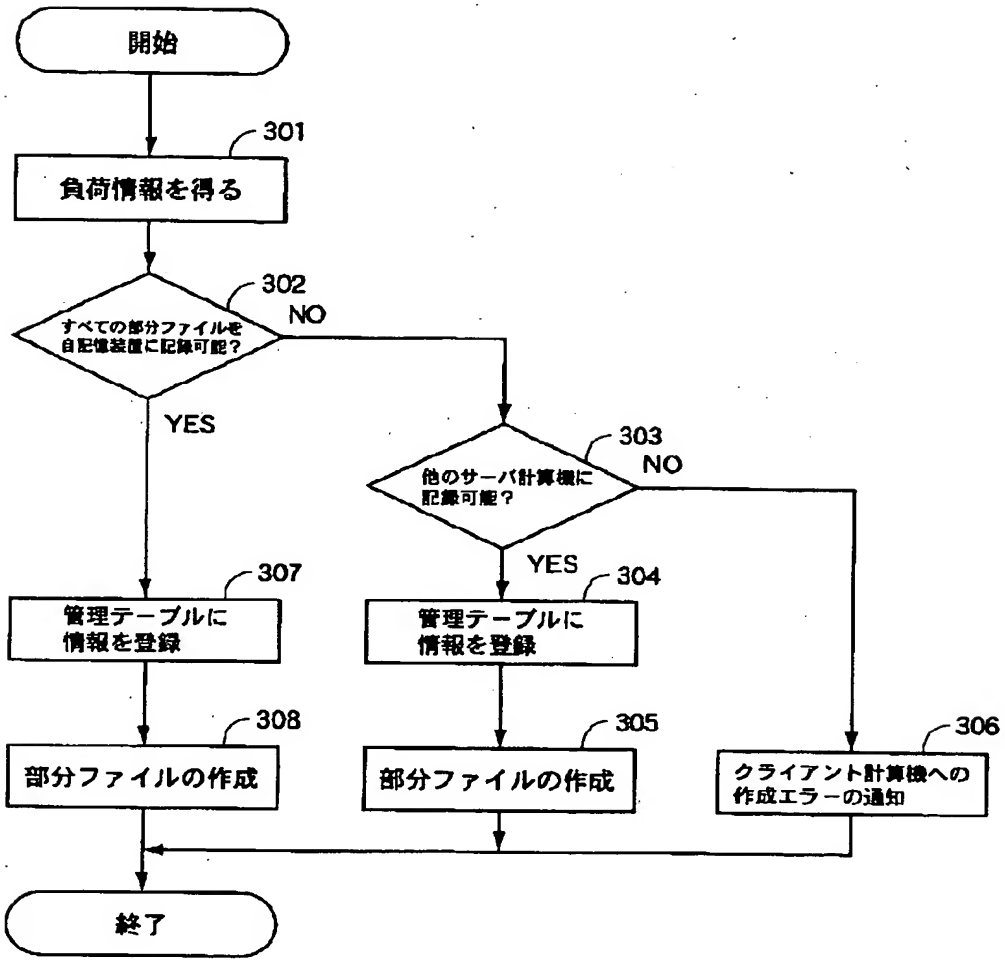

【図１２】

1201

部分ファイル識別子	単位時間あたりのアクセス回数	
	アクセス元サイト識別子	アクセス回数
A1	site B	10
A2	site A	2
B1	site C	5
⋮	⋮	
⋮	⋮	

【図１３】

1301

部分ファイル識別子	所在地	オリジナル所在地
A1	file://site A/server A/Disk ID 1/	file://site A/server A/Disk ID 1/
A2	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
A3	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
B1	file://site A/server A/Disk ID 2/	file://site A/server A/Disk ID 2/
C1	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
C2	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
⋮	⋮	
⋮	⋮	

【図１９】

1901

送出元サイト	送出先サイト	通信時間
site A	site B	10 ms
site B	site A	20 ms

【図７】

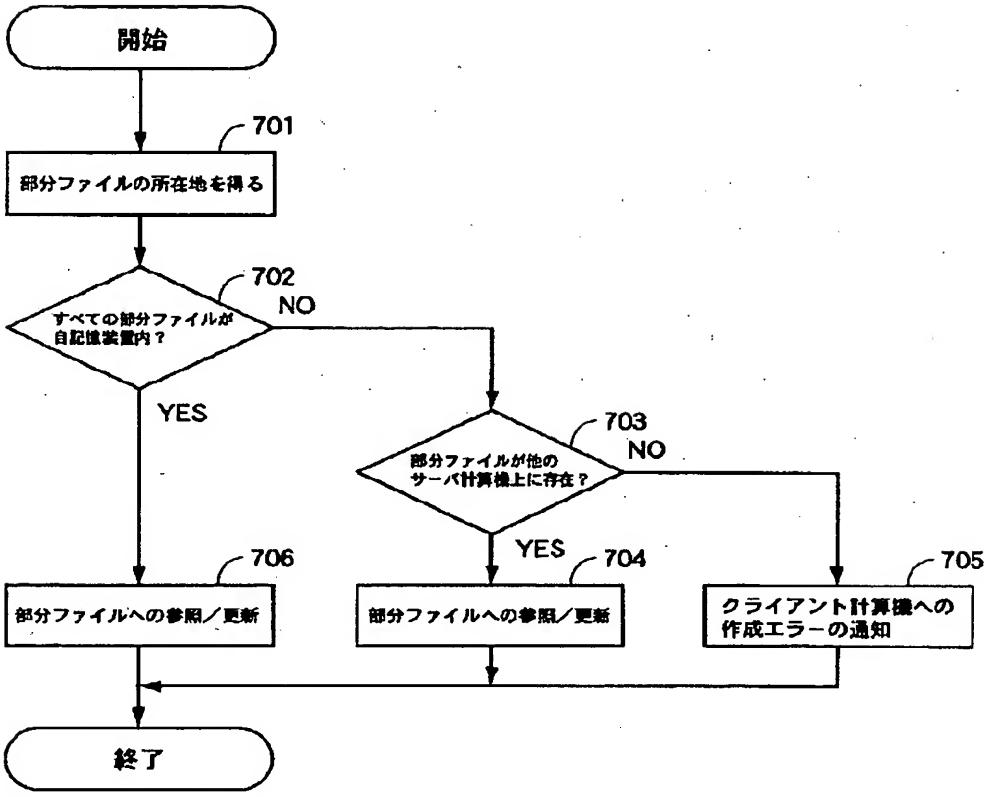

【図１４】

(A)

1401

部分ファイル識別子	所在地	オリジナル所在地
A1	file://site A/server A/Disk ID 1/	file://site A/server A/Disk ID 1/
A2	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
A3	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
B1	file://site A/server A/Disk ID 1/	file://site A/server A/Disk ID 1/
C1	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
C2	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
⋮	⋮	
⋮	⋮	

(B)

1402

部分ファイル識別子	所在地	オリジナル所在地
C1	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
C2	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
⋮	⋮	
⋮	⋮	

(C)

1403

部分ファイル識別子	所在地	オリジナル所在地
A2	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
A3	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
⋮	⋮	
⋮	⋮	

【図１５】

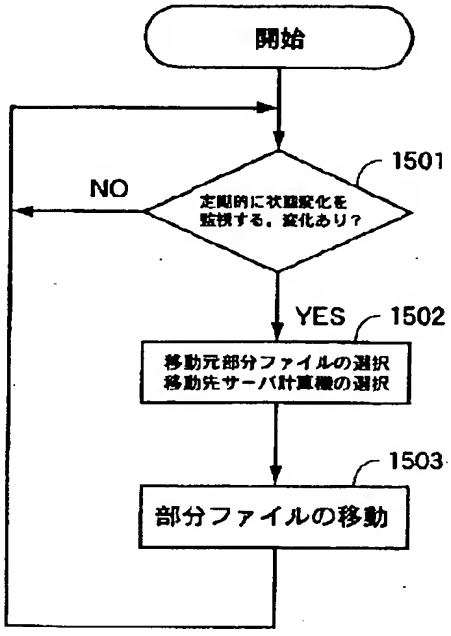

【図８】

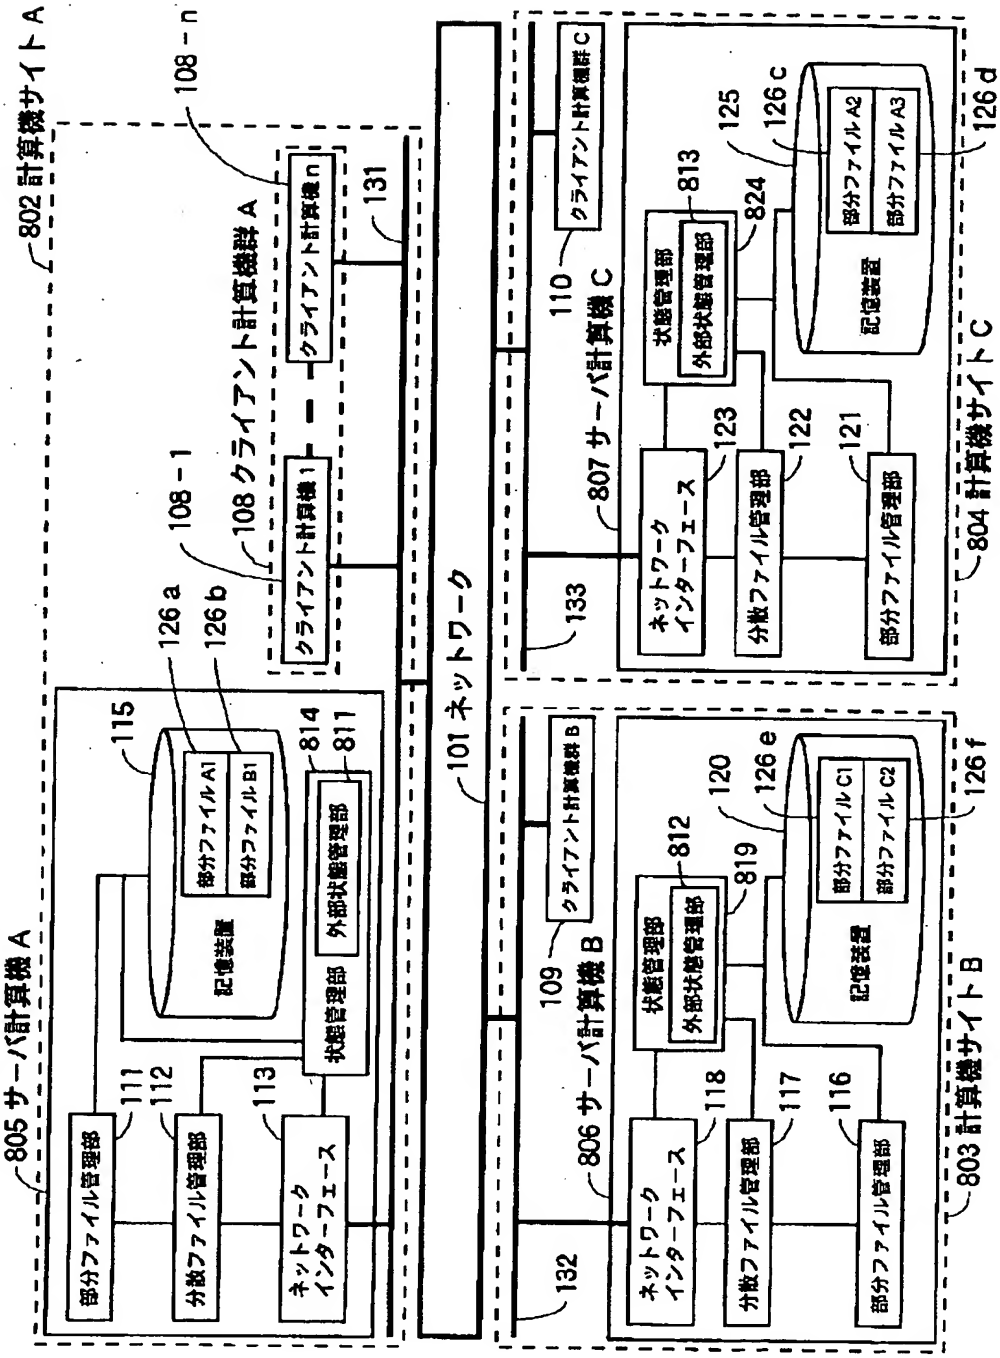
802 計算機サイトA
805 サーバ計算機A
108 - n
108 - 1
108 クライアント計算機群A
クライアント計算機n
クライアント計算機1
131
126 a
126 b
115
部分ファイルA1
部分ファイルB1
記憶装置
814
811
外部状態管理部
状態管理部
111
112
113
部分ファイル管理部
分散ファイル管理部
ネットワーク インターフェース
101 ネットワーク
132
806 サーバ計算機B
109
クライアント計算機群B
812
819
120
126 e
126 f
部分ファイルC1
部分ファイルC2
118
117
116
803 計算機サイトB
133
807 サーバ計算機C
110
クライアント計算機群C
813
824
125
126 c
126 d
部分ファイルA2
部分ファイルA3
123
122
121
804 計算機サイトC

【図１０】

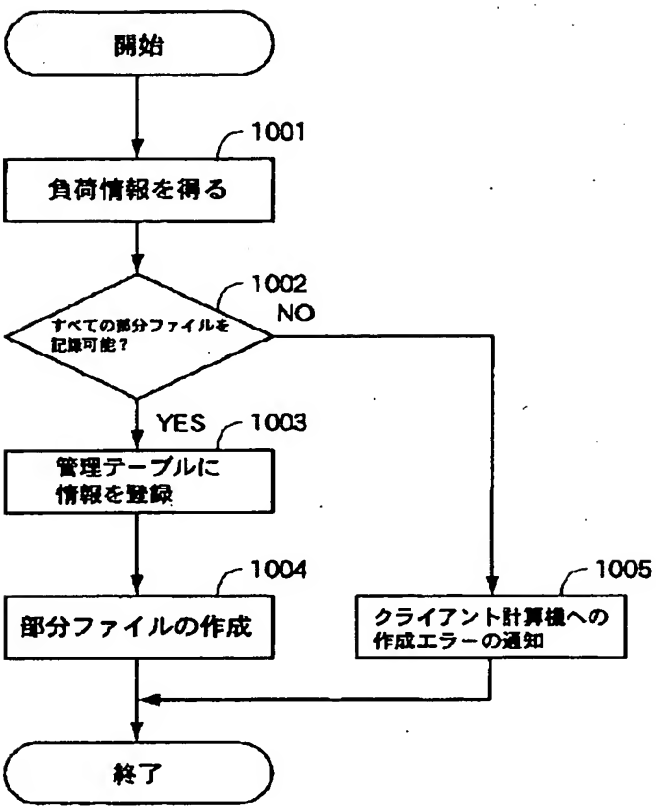

【図１６】

(A)

1601

部分ファイル識別子	所在地	オリジナル所在地
A1	file://site C/server C/Disk ID 2/	file://site A/server A/Disk ID 1/
A2	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
A3	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
B1	file://site A/server A/Disk ID 1/	file://site A/server A/Disk ID 1/
C1	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
C2	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
⋮	⋮	
⋮	⋮	

(B)

1602

部分ファイル識別子	所在地	オリジナル所在地
C1	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
C2	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
⋮	⋮	
⋮	⋮	

(C)

1603

部分ファイル識別子	所在地	オリジナル所在地
A2	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
A3	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
A1	file://site C/server C/Disk ID 2/	file://site A/server A/Disk ID 1/
⋮	⋮	
⋮	⋮	

【図１７】

(A)

1701

部分ファイル識別子	所在地	オリジナル所在地
A1	file://site B/server B/Disk ID 2/	file://site A/server A/Disk ID 1/
A2	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
A3	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
B1	file://site A/server A/Disk ID 1/	file://site A/server A/Disk ID 1/
C1	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
C2	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
⋮	⋮	
⋮	⋮	

(B)

1702

部分ファイル識別子	所在地	オリジナル所在地
C1	file://site C/server C/Disk ID 2/	file://site B/server B/Disk ID 3/
C2	file://site B/server B/Disk ID 2/	file://site B/server B/Disk ID 3/
A1	file://site B/server B/Disk ID 2/	file://site A/server A/Disk ID 1/
⋮	⋮	
⋮	⋮	

(C)

1703

部分ファイル識別子	所在地	オリジナル所在地
A2	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
A3	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
C1	file://site C/server C/Disk ID 2/	file://site B/server B/Disk ID 3/
⋮	⋮	
⋮	⋮	

【図１８】

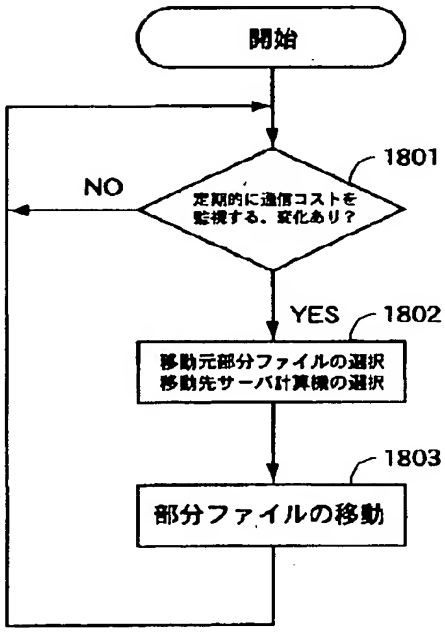

【図１１】

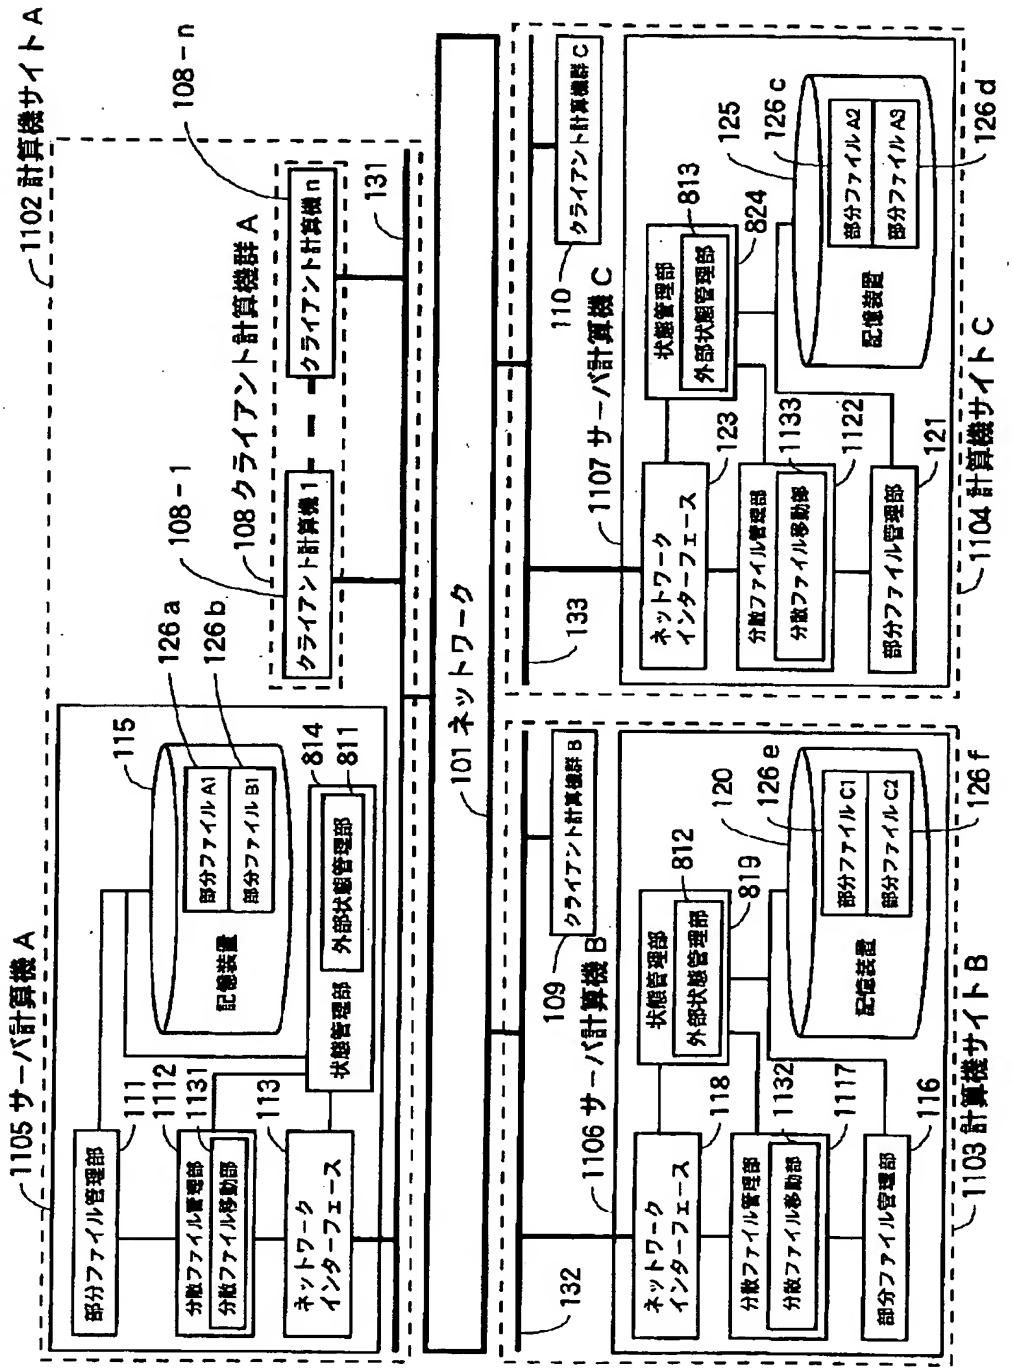
1102 計算機サイトA
1105 サーバ計算機A
部分ファイル管理部
111
分散ファイル管理部
分散ファイル移動部
1112
1131
ネットワークインターフェース
113
記憶装置
部分ファイルA1
部分ファイルB1
115
126a
126b
状態管理部
外部状態管理部
814
811
108-1
108 クライアント計算機群A
クライアント計算機1
クライアント計算機n
108-n
131
101 ネットワーク
1103 計算機サイトB
1106 サーバ計算機B
109
クライアント計算機群B
ネットワークインターフェース
118
分散ファイル管理部
分散ファイル移動部
1132
1117
部分ファイル管理部
116
状態管理部
外部状態管理部
812
819
120
126e
部分ファイルC1
部分ファイルC2
126f
132
1104 計算機サイトC
1107 サーバ計算機C
110
クライアント計算機群C
ネットワークインターフェース
123
分散ファイル管理部
分散ファイル移動部
1133
1122
部分ファイル管理部
121
状態管理部
外部状態管理部
813
824
125
126c
部分ファイルA2
部分ファイルA3
126d
133

【図２０】

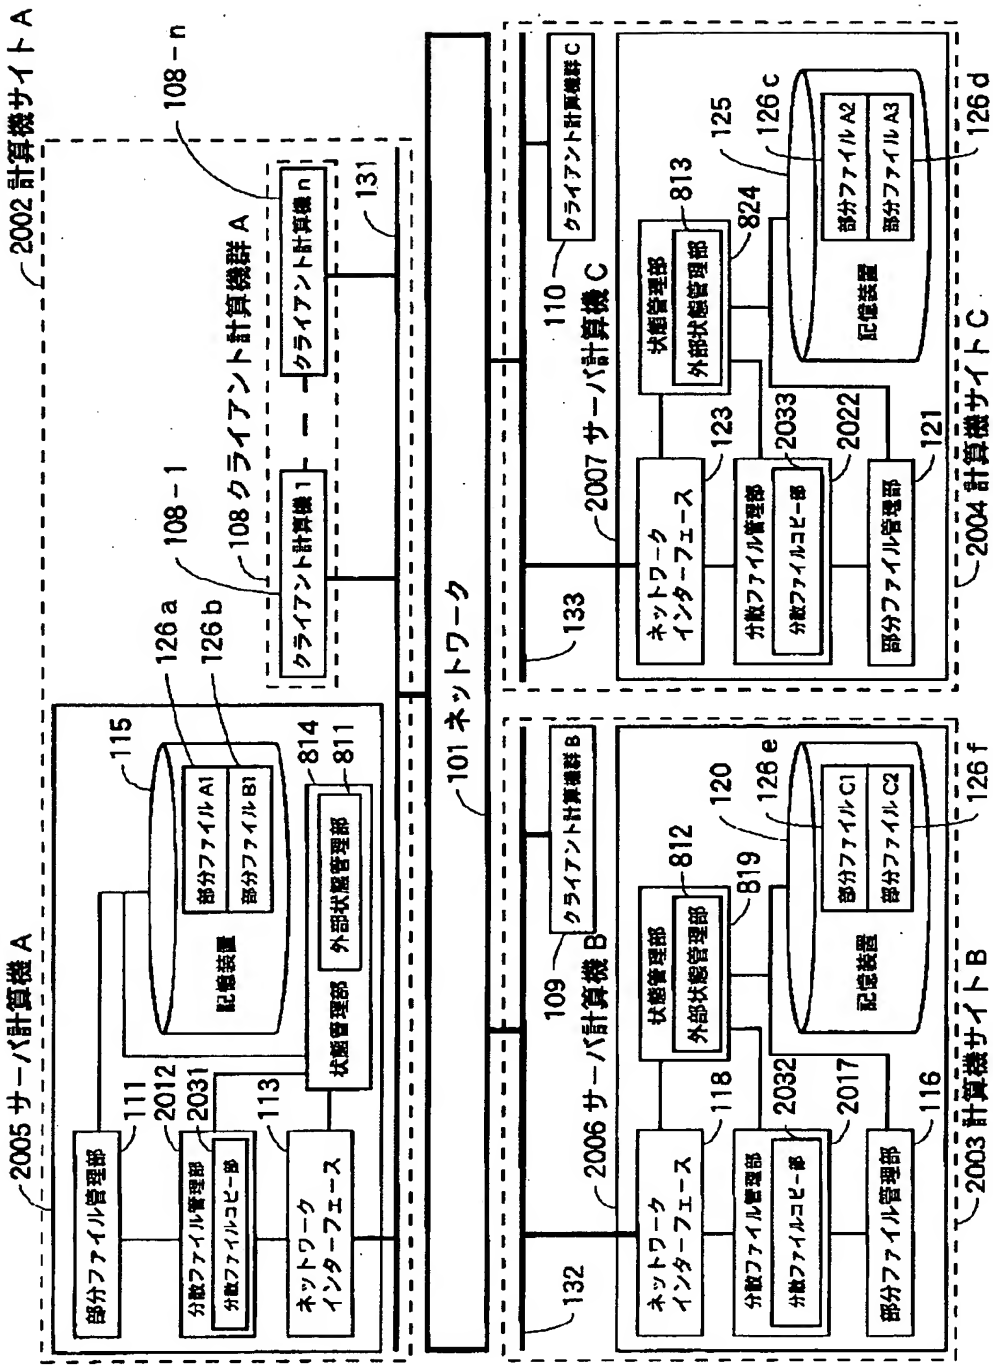
2002 計算機サイト A
2005 サーバ計算機 A
部分ファイル管理部
111
分散ファイル管理部
2012
分散ファイルコピー部
2031
ネットワーク インターフェース
113
記憶装置
115
部分ファイル A1
部分ファイル B1
126 a
126 b
状態管理部
814
外部状態管理部
811
101 ネットワーク
108 クライアント計算機群 A
108 - 1
クライアント計算機 1
108 - n
クライアント計算機 n
131
2006 サーバ計算機 B
109
クライアント計算機群 B
132
2003 計算機サイト B
2007 サーバ計算機 C
110
クライアント計算機群 C
133
2004 計算機サイト C
813
125
126 c
824
123
2033
2022
121
126 d
812
120
126 e
819
118
2032
2017
116
126 f
部分ファイル C1
部分ファイル C2
部分ファイル A2
部分ファイル A3

【図２１】

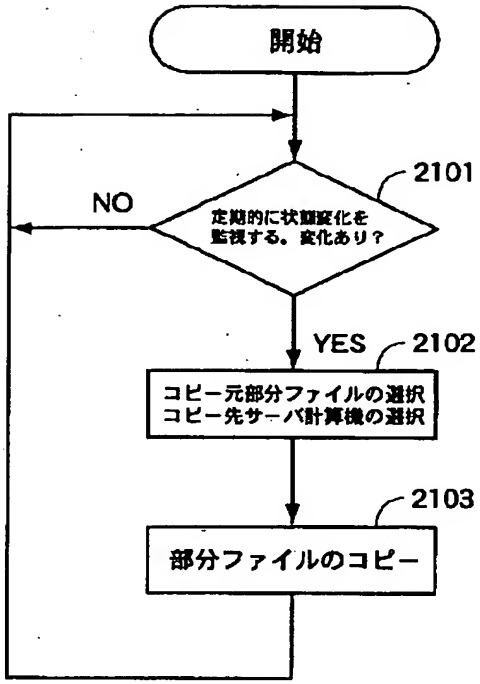

【図２２】

(A)

2201

部分ファイル識別子	所在地	オリジナル所在地
A1	file://site A/server A/Disk ID 1/ file://site C/server C/Disk ID 2/	file://site A/server A/Disk ID 1/
A2	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
A3	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
B1	file://site A/server A/Disk ID 1/	file://site A/server A/Disk ID 1/
C1	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
C2	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
⋮	⋮	
⋮	⋮	

(B)

2202

部分ファイル識別子	所在地	オリジナル所在地
C1	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
C2	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
⋮	⋮	
⋮	⋮	

(C)

2203

部分ファイル識別子	所在地	オリジナル所在地
A2	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
A3	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
A1	file://site C/server C/Disk ID 2/	file://site A/server A/Disk ID 1/
⋮	⋮	
⋮	⋮	

【図２３】

(A)

2301

部分ファイル識別子	所在地	オリジナル所在地
A1	file://site A/server A/Disk ID 1/ file://site C/server C/Disk ID 2/ file://site B/server B/Disk ID 3/	file://site A/server A/Disk ID 1/
A2	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
A3	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
B1	file://site A/server A/Disk ID 1/	file://site A/server A/Disk ID 1/
C1	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
C2	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
⋮	⋮	
⋮	⋮	

(B)

2302

部分ファイル識別子	所在地	オリジナル所在地
C1	file://site B/server B/Disk ID 3/ file://site C/server C/Disk ID 2/	file://site B/server B/Disk ID 3/
C2	file://site B/server B/Disk ID 3/	file://site B/server B/Disk ID 3/
A1	file://site B/server B/Disk ID 2/	file://site A/server A/Disk ID 1/
⋮	⋮	
⋮	⋮	

(C)

2303

部分ファイル識別子	所在地	オリジナル所在地
A2	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
A3	file://site C/server C/Disk ID 2/	file://site C/server C/Disk ID 2/
A1	file://site C/server C/Disk ID 2/	file://site A/server A/Disk ID 1/
C1	file://site C/server C/Disk ID 2/	file://site B/server B/Disk ID 3/
⋮	⋮	
⋮	⋮	

【図２４】

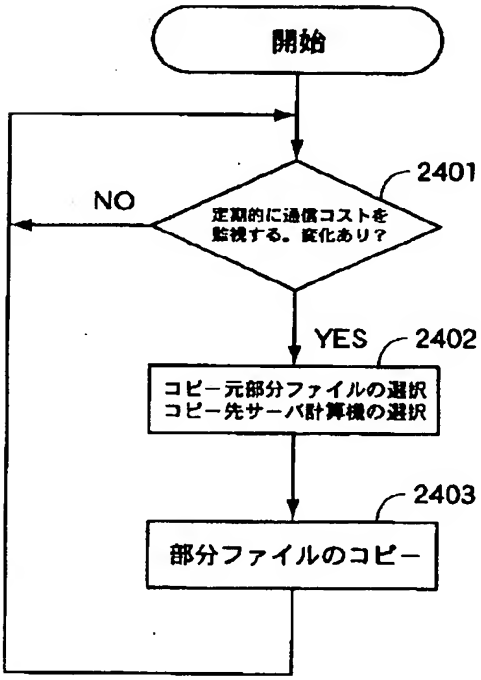

【図２５】

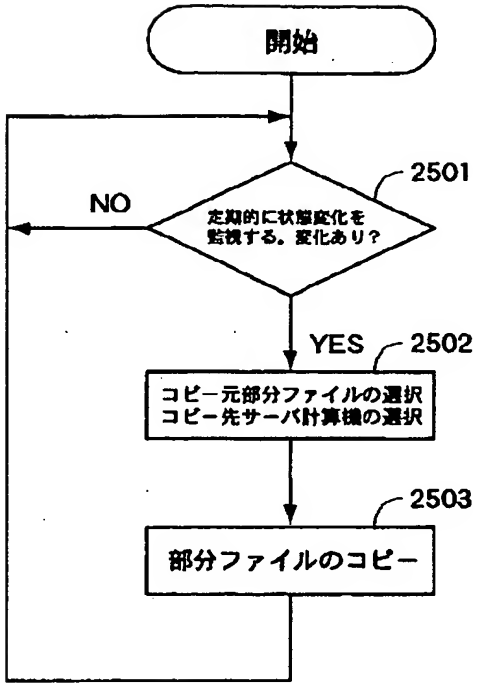
開始
2501
NO
定期的に状態変化を監視する。変化あり？
YES
2502
コピー元部分ファイルの選択
コピー先サーバ計算機の選択
2503
部分ファイルのコピー

【図２８】

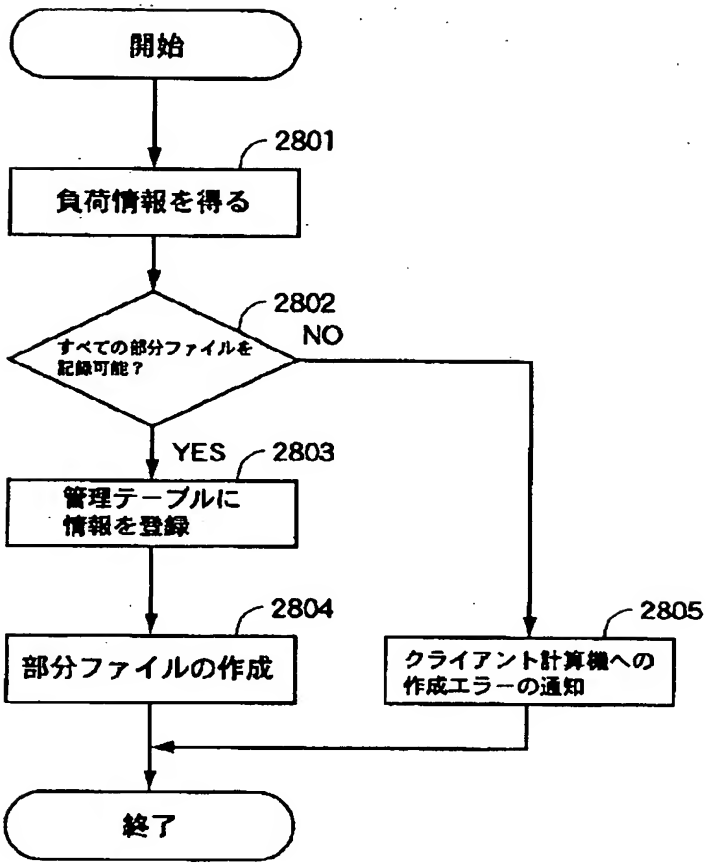
開始
2801
負荷情報を得る
2802
NO
すべての部分ファイルを記録可能？
YES
2803
管理テーブルに情報を登録
2804
部分ファイルの作成
2805
クライアント計算機への作成エラーの通知
終了

【図２９】

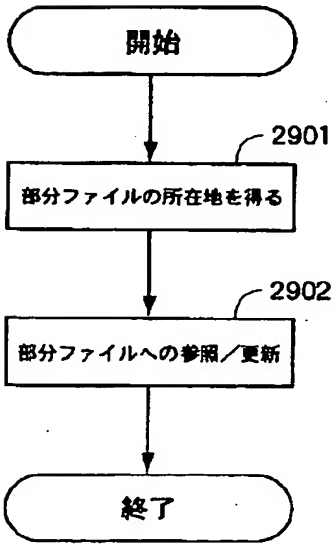
開始
2901
部分ファイルの所在地を得る
2902
部分ファイルへの参照／更新
終了

【図２６】

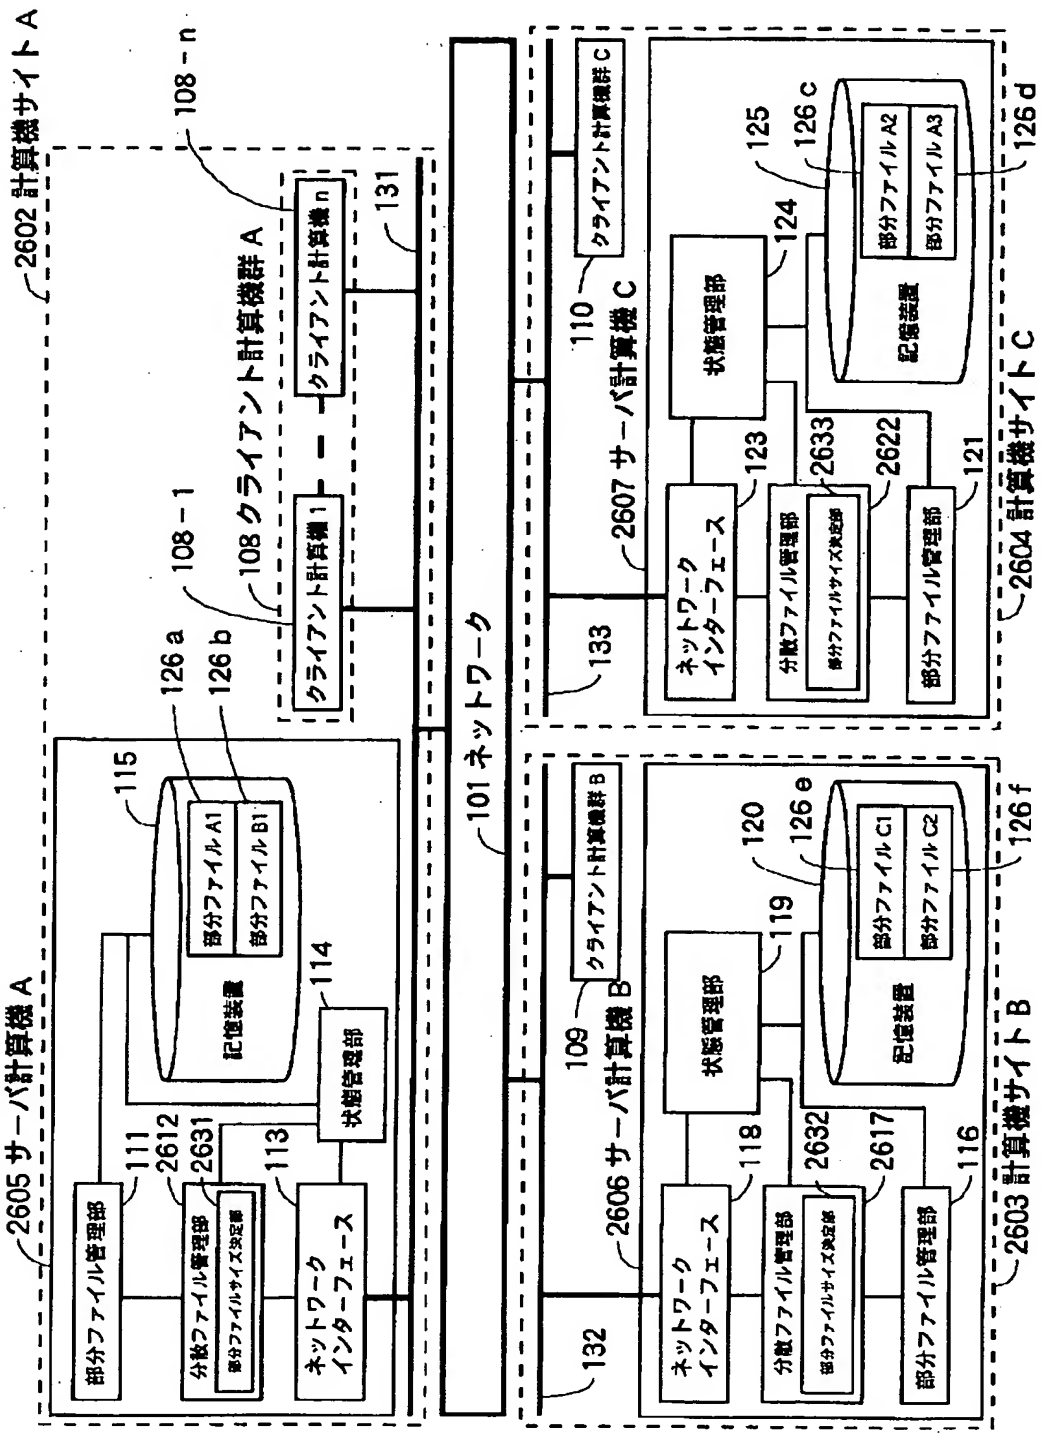
2602 計算機サイト A
2605 サーバ計算機 A
2606 サーバ計算機 B
2607 サーバ計算機 C
2603 計算機サイト B
2604 計算機サイト C
101 ネットワーク
108 クライアント計算機群 A
108 - 1
108 - n
クライアント計算機 1
クライアント計算機 n
クライアント計算機群 B
クライアント計算機群 C
部分ファイル管理部
分散ファイル管理部
部分ファイルサイズ決定部
ネットワーク インターフェース
状態管理部
記憶装置
部分ファイル A1
部分ファイル B1
部分ファイル C1
部分ファイル C2
部分ファイル A2
部分ファイル A3
111
2612
2631
113
114
115
116
2617
118
119
120
121
2622
123
124
125
126 a
126 b
126 c
126 d
126 e
126 f
131
132
133
2632
2633
109
110

【図２７】

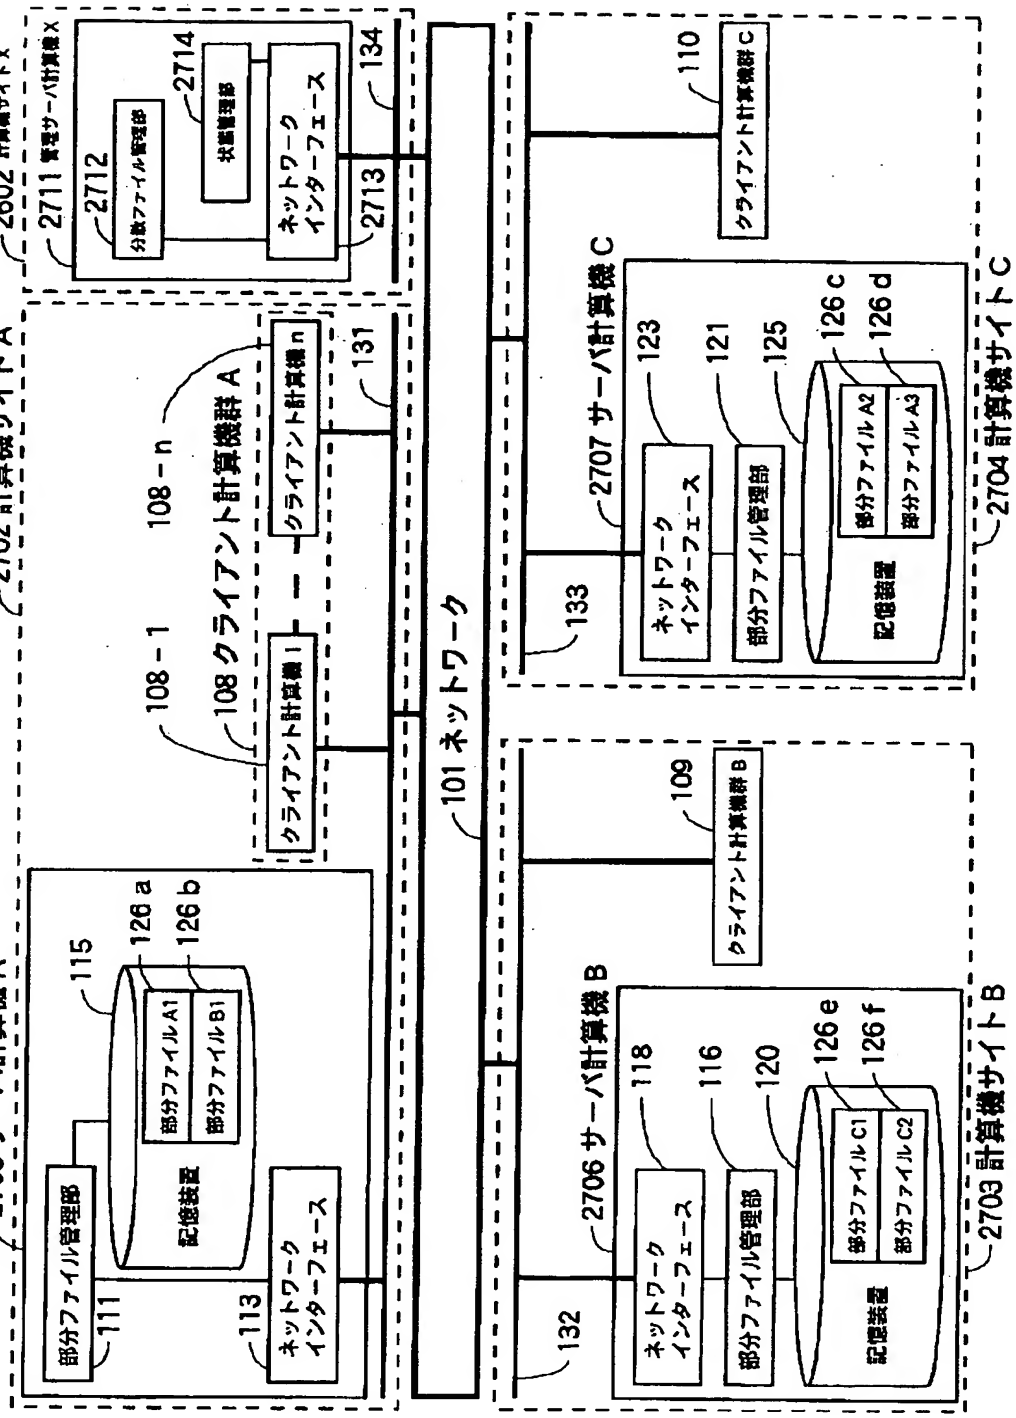
2602 計算機サイトX
2711 管理サーバ計算機X
2712
分散ファイル管理部
2714
状態管理部
ネットワーク
インターフェース
2713
134
2702 計算機サイトA
2705 サーバ計算機A
部分ファイル管理部
111
115
126 a
126 b
部分ファイル A1
部分ファイル B1
記憶装置
ネットワーク
インターフェース
113
108 クライアント計算機群A
108 - 1
クライアント計算機1
108 - n
クライアント計算機n
131
101 ネットワーク
2707 サーバ計算機C
123
121
125
126 c
126 d
部分ファイル A2
部分ファイル A3
ネットワーク
インターフェース
部分ファイル管理部
記憶装置
133
110
クライアント計算機群C
2704 計算機サイトC
2706 サーバ計算機B
118
116
120
126 e
126 f
部分ファイル C1
部分ファイル C2
ネットワーク
インターフェース
部分ファイル管理部
記憶装置
132
109
クライアント計算機群B
2703 計算機サイトB

【図３０】

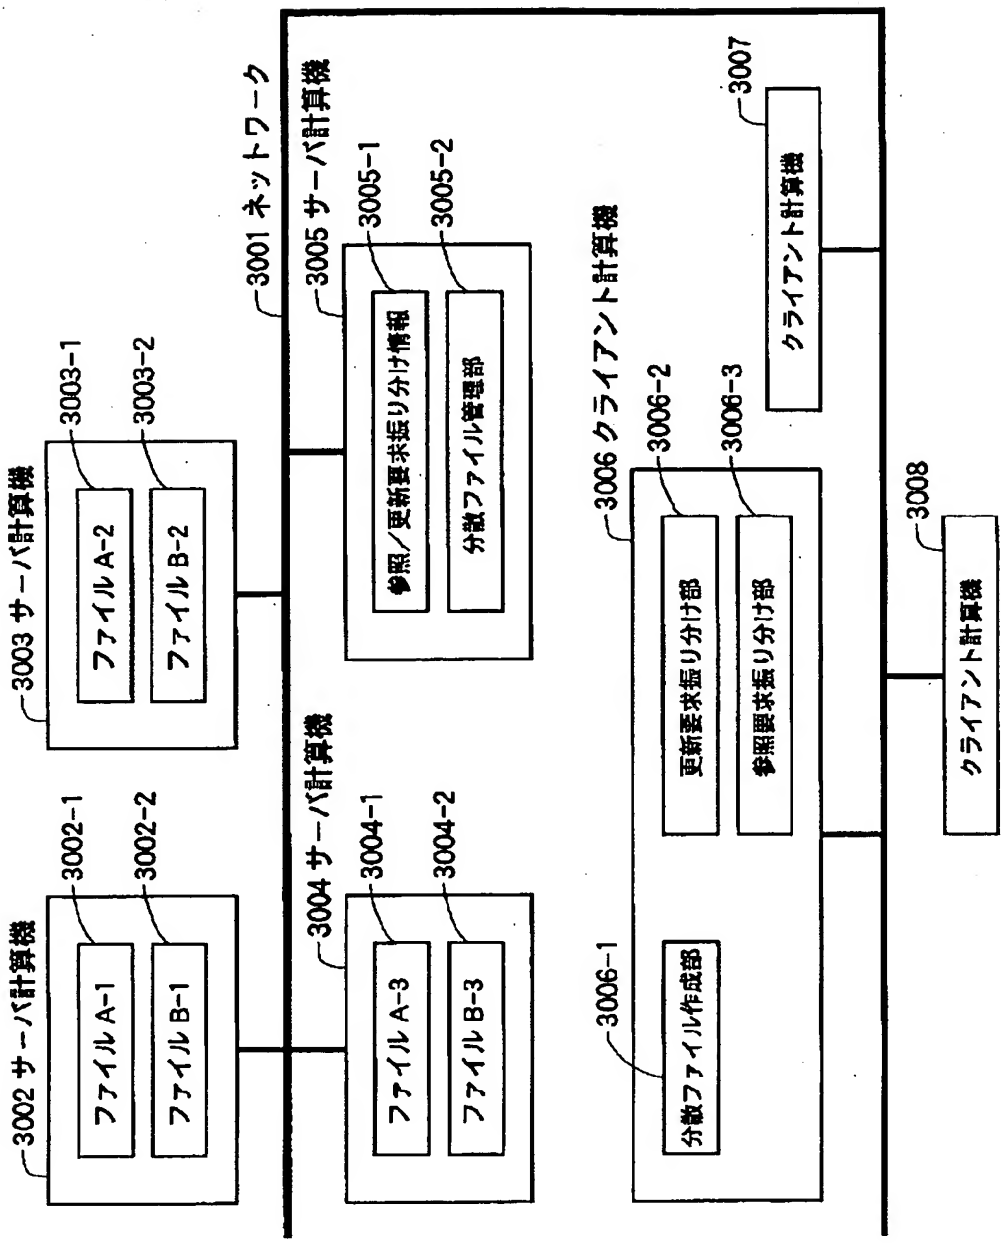

フロントページの続き

(72)発明者　安河内　龍二
大阪府門真市大字門真1006番地　松下電器産業株式会社内

(72)発明者　田中　則子
大阪府門真市大字門真1006番地　松下電器産業株式会社内

Fターム(参考)　5B045 BB49 DD16 GG02 GG09 JJ08
5B082 HA01 HA08

PATENT ABSTRACTS OF JAPAN

(11)Publication number : 08-335144
(43)Date of publication of application : 17.12.1996

(51)Int.Cl. G06F 3/06
G06F 11/20
G06F 12/16
G06F 13/14

(21)Application number : 07-139781
(22)Date of filing : 07.06.1995

(71)Applicant : HITACHI LTD
(72)Inventor : MATSUMOTO YOSHIKO
MURAOKA KENJI

(54) EXTERNAL STORAGE DEVICE

(57)Abstract:
PURPOSE: To improve reliability and performance and to provide non-stop maintenance by distributing a load to the plural storage controllers of redundant configuration.
CONSTITUTION: Plural disk drive controllers 200 and 400 of redundant configuration for controlling a disk device are connected to a host device by the same SCSIID, the monitor of mutual operating states and the setting of load distribution information are performed by interposing a communication mechanism 300 and a common managing table 310 and in a normal state, high performance is provided by distributing the load by simultaneously operating the plural disk drive controllers 200 and 400 but in case of fault or maintenance, non-stop operation and non-stop maintenance are provided by executing a switching operation at the degeneracy and recovery caused by disconnection on the side of the fault while using switching mechanism 220 and 420.

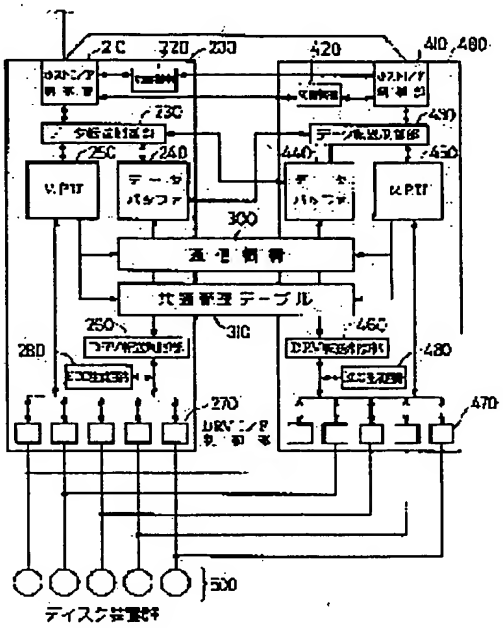

LEGAL STATUS

[Date of request for examination] 06.06.2002
[Date of sending the examiner's decision of rejection]
[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]
[Date of final disposal for application]
[Patent number]
[Date of registration]
[Number of appeal against examiner's decision of rejection]
[Date of requesting appeal against examiner's decision of rejection]
[Date of extinction of right]

* NOTICES *

1. This document has been translated by computer.So the translation may not reflect the original precisely.
2. **** shows the word which can not be translated.
3.In the drawings, any words are not translated.

CLAIMS

[Claim(s)]
[Claim 1] External storage containing two or more memory control units which intervene between the storage with which the data delivered and received between the high order equipment characterized by providing the following are stored, and the aforementioned storage and the aforementioned high order equipment, and control transfer of the aforementioned data between the aforementioned high order equipment and the aforementioned storage. An interface means to connect the memory control unit concerned to the aforementioned high order equipment so that two or more aforementioned memory control units may look equivalent [in view of the aforementioned high order equipment]. A surveillance means to be prepared in each aforementioned memory control unit, and to supervise the existence of the obstacle in other aforementioned memory control units, or change instructions. The change means which changes whether which aforementioned memory control unit controls transfer of the aforementioned data between the aforementioned high order equipment by being prepared in each aforementioned memory control unit. A communication-of-information means to transmit the mutual information of the aforementioned memory control unit, and a load-distribution means to make the load which originates in input/output request from the aforementioned high order equipment share among two or more aforementioned memory control units.
[Claim 2] External storage according to claim 1 characterized by providing the following. The data buffer which stores temporarily the aforementioned data which are prepared in each of two or more aforementioned memory control units, and are delivered and received between the aforementioned high order equipment. While writing write request data in alternative or multiplex to each of two or more aforementioned data buffers at the time of the write request from the aforementioned high order equipment Are at the write-in completion time to the aforementioned data buffer of the aforementioned write request data, and write in to the aforementioned high order equipment and completion is reported. The light after processing in which the aforementioned write request data are made to reflect from the aforementioned data buffer to the aforementioned storage asynchronously [the input/output request from the aforementioned high order equipment]. And they are the data transfer control means which can be performed alternatively about the write-through processing which it is at the write-in completion time to the aforementioned storage of the aforementioned write request data, and writes in to the aforementioned high order equipment and reports completion.
[Claim 3] External storage according to claim 1 or 2 characterized by providing the following. The 1st management information for being made accessible in common from two or more aforementioned memory control units, and discriminating whether each aforementioned memory control unit is healthy, The 2nd management information which specifies any shall be performed between the aforementioned light after processing and the aforementioned write-through processing, A management information storage means by which at least one of the 3rd management information which specifies any of two or more aforementioned memory control units receive the input/output request from the aforementioned high order equipment, and the 4th management information which specifies the assignment of the aforementioned load in each of two or more aforementioned memory control units is stored. The control logic carry out

operation of performing degeneracy operation which continues transfer of the aforementioned data between the aforementioned high order equipment by the aforementioned remaining memory control unit while separating the aforementioned memory control unit which the aforementioned obstacle occurred ignited by generating of an obstacle, or the change instructions from the outside, or was ordered from the outside, and operation return the separated aforementioned memory control unit to a redundant configuration.
[Claim 4] It is the external storage characterized by having the control logic which performs a halt and resumption of alternative write-in operation of the aforementioned write request data to each of the aforementioned data buffer by which the aforementioned data transfer control means were prepared in each of each aforementioned memory control unit in external storage according to claim 2.
[Claim 5] External storage characterized by performing maintenance of the micro program which controls the maintenance or the aforementioned memory control unit of a data buffer corresponding to the stopped aforementioned memory control unit while stopping at least one in two or more aforementioned memory control units alternatively and performing degeneracy operation in external storage according to claim 4.

[Translation done.]

* NOTICES *

1.This document has been translated by computer. So the translation may not reflect the original precisely.
2.**** shows the word which can not be translated.
3.In the drawings, any words are not translated.

DETAILED DESCRIPTION

[Detailed Description of the Invention]
[0001]
[Industrial Application] Especially this invention is applied to the external-memory subsystem of the redundant configuration which equipped multiplex with the input/output control unit which controls the input/output request of the information from high order equipment etc. about external storage, and relates to effective technology.
[0002]
[Description of the Prior Art] In the external storage which constitutes a computer system, when the memory control unit which intervenes between storage and high order equipment equipped with the storage, and controls transfer of the information between both is not a redundant configuration, if an obstacle occurs in a memory control unit, a subsystem will be obliged to a halt and a rehabilitation work will be performed in the meantime. And an end of this rehabilitation work resumes the business which the memory control unit was rebooted, or the subsystem was rebooted, and had been interrupted till then.
[0003] Moreover, recently, the employment gestalt of operation is increasing 24 hours in various information processing business which uses a computer system, and continuous running is demanded also of the external-memory subsystem. For this reason, for example, the technology whose continuation operation of a system one memory control unit tends to enable by the memory control unit of on stream and an other system stopping, and taking redundant composition about a memory control unit [say / taking a standby state], and changing to the memory control unit of the standby state of an other system at the time of the obstacle of a memory control unit is known as indicated by JP,3-206529,A.
[0004]
[Problem(s) to be Solved by the Invention] However, in the above-mentioned conventional technology, although continuous running at the time of an obstacle was possible, in spite of having had two sets of memory control units, actually working is only any one set and it did not change at all with the time of one set efficiently. That is, it was redundant, and also the memory control unit of a system could not but be an object for hot standbies to the last, and could not but be a mere alternative of the memory control unit of an obstacle.
[0005] Moreover, in recent years, the demand to a system was also various, there were various topologies by which an access demand is published from high order equipment to two or more paths to the same storage or separate storage, and it was difficult to build a system in the mere redundant configuration of a memory control unit like before according to various users' request.

[0006] Moreover, in the former, it has the composition that the memory control unit and the data buffer were carried in one board in the cheap system. When performing maintenance control, such as extension of the data buffer in a memory control unit, separation of only a data buffer Eye an impossible hatchet, A data buffer is extended in the state where the system was made to suspend. After the end of extension work, It was impossible to have carried out the maintenance control work of extension etc., having rebooted the memory control unit and the system, having completed the procedure of resuming the business interrupted till then, and processing the

input/output request (I/O) from high order equipment.
[0007] The purpose of this invention is by making two or more memory control units of a redundant configuration distribute a load to offer the external storage which can raise reliability and a performance.
[0008] Other purposes of this invention are to offer the external storage which can realize improvement in the reliability by multiplexing of a memory control unit, and control action with a still more various memory control unit, without making it conscious of the redundant configuration of a memory control unit to a high order equipment side.
[0009] The purpose of further others of this invention is to offer the external storage which can carry out the maintenance control work of the hardware in two or more memory control units of a redundant configuration, software, etc. simple, without stopping operation.
[0010] The purpose of further others of this invention is to offer the external storage which can do the maintenance control work of composition of having carried the memory control unit and the data buffer on the single board during operation.
[0011]
[Means for Solving the Problem] An interface means by which the external storage of this invention connects a memory control unit to high order equipment so that two or more memory control units may look the same [in view of high order equipment], A surveillance means to supervise other memory control units among two or more memory control units, and the means of communications which can transmit the information between memory control units, It considers as composition including the change means which changes the memory control unit which has received the demand from high order equipment, the input/output request from the high order equipment which one memory control unit received, and the load-distribution means which carries out the load distribution of the processing which accompanies it in two or more memory control units.
[0012] Moreover, the data buffer which once stores the write-in data from high order equipment by preparing for each memory control unit and taking the same redundant configuration as a memory control unit, When the write-in data from high order equipment are stored in a data buffer, while reporting an end to high order equipment and writing the demand with high order equipment in storage from a data buffer asynchronously It considers as composition including a data transfer means to control whether it writes in two or more data buffers of all of a redundant configuration, or it writes in alternatively.
[0013] Moreover, the 1st management information for being made accessible in common from two or more memory control units, and discriminating whether each memory control unit is healthy, The 2nd management information which specifies any shall be performed between light after processing and write-through processing, It considers as composition including a management information storage means by which at least one of the 3rd management information which specifies any of two or more memory control units receive the input/output request from high order equipment, and the management information [of ** the 4th which specifies the assignment of the load in each of two or more memory control units] **s is stored.

[0014]
[Function] In the external storage of this invention, when it is a redundant configuration containing the 1st of a couple, and the 2nd memory control unit, daisy chain connection is made with for example, high order equipment and a SCSI interface, and these the 1st and 2nd memory control units are accessed by the same SCSIID, for example. For example, when the 1st memory control unit has received the input/output request from high order equipment fixed, other 2nd memory control unit distributes based on the 4th management information which specifies the assignment of the load in each of two or more memory control units, and the load accompanying processing of the input/output request concerned can aim at improvement in the throughput of the radial transfer by parallel operation of the improvement in the reliability by the redundant configuration, the 1st, and 2nd memory control units.
[0015] Moreover, he does not need to be [as opposed to / a change / that what is necessary is just to publish an I/O demand to SCSIID also with after / same / high order equipment] an

obstacle by changing the memory control unit which detects an obstacle by the 1st management information and the surveillance means when the 1st memory control unit has received the input/output request from high order equipment fixed, for example and an obstacle occurs in the 1st memory control unit, and receives a demand by the change means to the 2nd memory control unit] conscious at all. Then, the memory control unit acting as the obstacle is separated, and it goes into degeneracy operation. The 1st memory control unit is restored after the maintenance-service end of parts, exchange of a micro program, etc., and it is restored to the original redundant configuration.

[0016] Moreover, have a data buffer in each memory control unit, and the 1st memory control unit receives the write-in data from high order equipment. When light after processing is being performed, a surveillance means detects that the obstacle occurred in the 1st memory control unit, by the change means When the memory control unit which receives input/output request is changed from the 1st memory control unit to the 2nd memory control unit, Simultaneously, it changes from the multiplex data write-in processing to two or more data buffers to the processing which writes data in the data buffer with which the memory control unit under operation was equipped alternatively.

[0017] At this time, it chooses whether light after processing is performed or write-through processing is performed. This selection is possible when a user sets up the 2nd management information of a management information storage means. That is, when the demand to a user's data reliability is high, and setting it as write-through mode and requiring a performance rather than reliability, it is set as light after mode.

[0018] It changes to the operation written in a data buffer by changing to alternative writing or multiplex writing multiplex after restoration of the 2nd memory control unit, and can restore to a redundant configuration.

[0019] After the 1st memory control unit receives the input/output request from high order equipment, and changing from the processing written in multiplex when double writing is performed to the data buffer of the 1st memory control unit, and the data buffer of the 2nd memory control unit and light after processing is being performed about the write request from high order equipment to the processing written in alternatively, separating the 2nd memory control unit, degenerating it and maintaining extension of a data buffer, exchange of a micro program, etc., the original redundant configuration is restored. Then, the 2nd memory control unit for means of communications of **** which can transmit the information between memory control units notifies completion of maintenance services, such as extension of a data buffer, to the 1st memory control unit, and changes receipt of the demand from high order equipment to self-equipment after a notice using a change means.

[0020] On the other hand, the 1st memory control unit which received the notice degenerates self-equipment, maintains extension of a data buffer etc. and makes it restore. The 1st memory control unit notifies the completion of maintenance of extension of a data buffer etc. to the 2nd memory control unit after restoration using the means of communications which can transmit informational. Ignited by this, it changes from the alternative data writing to a single data buffer to the multiplex write-in processing to two or more data buffers. Thereby, it becomes possible, continuing the radial transfer [business / maintenance control /, such as extension of the data buffer of the 1st memory control unit of a couple, and the 2nd memory control unit, and exchange of a micro program,] between high order equipment.

[0021] Moreover, according to this invention, the 1st memory control unit and the 2nd memory control unit can judge any receive the demand from high order equipment by referring to the 3rd management information which specifies any of two or more aforementioned memory control units set as the management information storage means receive the input/output request from the aforementioned high order equipment. It is also possible for this to receive and process input/output request in the memory control unit of either the 1st memory control unit or the 2nd memory control unit not only receiving the demand from high order equipment but both. Moreover, it becomes possible by setting up the 3rd management information optionally by the user to specify from a user the memory control unit which receives the demand from high order equipment to be arbitration.

[0022]

[Example] Hereafter, the example of this invention is explained in detail, referring to a drawing.

[0023] Drawing 1 is the conceptual diagram showing an example of the computing system containing the external storage which is one example of this invention. The computing system of this example contains the high order equipment 100 which is a central processing unit, the disk drive control unit 200 and the disk drive control unit 400, and the disk unit 500. The disk drive control unit 200 and the disk drive control unit 400 were connected with high order equipment 100 with the daisy chain of a SCSI interface, the same SCSIID was set up and the disk drive control unit 200,400 has taken the redundant configuration. And in the case of this example, the disk drive control unit 200 receives the demand from high order equipment 100, performs processing which accompanies a demand with the disk drive control unit 200 and the redundant disk drive control unit 400, and controls a disk unit 500. [0024] Drawing 2 is the block diagram showing an example of the internal configuration of the disk drive control units 200 and 400. In addition, since the internal configuration of the disk drive control unit 200 and the disk drive control unit 400 is the same, the disk drive control unit 200 is explained to an example, 2 figures is made the same under the sign of the part which corresponds about the disk drive control unit 400 side, and explanation is omitted.

[0025] a microprocessor unit 250 (Following MPU is called) is performed decoding a RAM (RAM -- not shown) serially, and is controlling the whole disk drive control unit 200

[0026] The host I/F control section 210 is performing protocol control with high order equipment 100. The DRVI/F control section 270 is performing protocol control with each drive. A data buffer 240 is used at the time of the data transfer of the host I/F control section 210 and the DRVI/F control section 270. Volatilization memory is sufficient as this memory, and non-volatilized memory is sufficient as it. this example describes for an example the case where a data buffer 240 is built by volatilization memory.

[0027] The change mechanism 220 is for changing the host I/F control section which receives I/O from high order equipment 100 to the host I/F control section 210 and the host I/F control section 410 of each disk drive control unit 200 and the disk drive control unit 400. The host I/F control section 210 shall have received in this example. The data transfer control section 230 is controlling the data transfer of high order equipment 100 and a data buffer 240. It has the function of whether this data transfer control section 230 carries out double writing of the light data from high order equipment 100 to the 2nd page, a data buffer 240 and a data buffer 440, or to 1-fold carry out [of only a data buffer 240 / both] writing. Moreover, it is possible to change 1-fold writing or double writing with the directions from MPU250.

[0028] The DRV transfer control section 260 controls the data transfer between a data buffer 240 and a disk unit 500.

[0029] The transmitter style 300 is a mechanism for transmitting the information between MPU250 and MPU450. This transmitter style 300 is enabling the bidirectional transfer between MPU250 and MPU450.

[0030] The common managed table 310 is a managed table in which both refernce / renewal of MPU250 and MPU450 are possible.

[0031] this example takes and explains to an example the drive storing method by array composition which is distributed to two or more disk units 500, and stores the logical data from high order equipment 100.

[0032] The ECC generation circuit 280 has the function which generates redundant data to the data sent from high order equipment 100, and can use this function also for the reconstitution of data. 1 logical data unit sent from the high order is sufficient as the unit which adds redundant data, and it is good even to two or more logical data units. this example adds redundant data to four logical data, and describes them in RAID5 method which does not fix the drive which stores this redundant data.

[0033] Next, with reference to drawing 3 , an example of the composition of the common managed table 310 is explained. It is used for surveillance intelligence 320 confirming whether each disk drive control units 200/400 are operating normally. Surveillance intelligence A321 sets up information at a fixed interval, when MPU250 of the disk drive control unit 200 is normally

judged that operation is possible. Moreover, when MPU250 judges normally that operation is impossible, the information which shows abnormalities is set up. In addition, MPU450 of the disk drive control unit 400 as well as MPU250 sets information as surveillance intelligence B322.
[0034] The data transfer mode information 330 directs the end report opportunity to the light data write request from high order equipment 100 at the time of the degenerate state of a system. That is, it is this information at the write-in completion time to a data buffer 240 or a data buffer 440, and is the information for judging whether an end is reported to high order equipment 100, or an end report is carried out when it writes even in a disk unit 500 from a data buffer 240 (write-through mode being called below) (light after mode being called below).
[0035] The directions information on a disk drive control unit that the host I/O receipt information 340 receives I/O between two disk drive control units 200/400 is shown. this example explains as that by which the disk drive control unit 200 is set as the host I/O receiving side.
[0036] The load-distribution information 350 is information for carrying out the load distribution of the processing accompanying I/O from high order equipment between [of two] disk drive control unit 200 / 400. The method of a load distribution may divide into each disk drive control unit the disk unit made applicable to access, and may share it with the processing which stores light data in a disk unit 500 from a data buffer with asynchronous processing of the I/O demand from high order equipment 100 and I/O demand from high order equipment 100. Or the method of performing processing is sufficient as the way which writes in all the matters that must be processed into load-distribution information, considers as competition logic between two MPU, and has an opening as MPU.
[0037] By this example, processing of the I/O demand from high order equipment 100 and the I/O demand from high order equipment 100 explain the method shared with the processing which stores light data in a disk unit 500 from data buffers 240/440 asynchronously. Therefore, in this example, the information on the light data stored in data buffers 240/440 shall be contained in the load-distribution information 350.
[0038] Next, the write-in processing and reading processing of data to a disk unit 500 are explained from the high order equipment 100 in the computing system in this example.
[0039] Usually, at the time of the write request from high order equipment 100, by the host I/F control section 210, the disk drive control unit 200 receives write-in logical data, stores it in a data buffer 240 and a data buffer 440 doubly by the data transfer control section 230, sets storing information as the load-distribution information 350 on the common managed table 310, and reports an end to high order equipment 100 at this time. Serially, if MPU450 has storing information with reference to the load-distribution information 350 The light data concerned and the data of the same address already stored in the drive (the old data are called below), The parity data corresponding to the light data concerned are read from a disk unit 500 by the DRVI/F control section 470 and the DRV transfer control section 460. Light data, the old data, and parity data generate the parity data (new parity data are called below) corresponding to light data in the ECC generation circuit 480. Light data are stored in a disk unit 500 by writing the new parity data and light data which were generated in a disk unit 500 by the DRVI/F control section 470 and the DRV transfer control section 460. This processing is asynchronously performed with the I/O demand from high order equipment 100. Moreover, the read-out processing of the old data / old parity data performed since light data are stored and new parity generation processing, and new parity data storage processing are called light penalty in RAID5.
[0040] Thus, the storing demand of the light data from high order equipment 100 is processing that a load is very high, when operating two or more disk units 500 as disk array equipment. Efficiency leads to the improvement in a performance as a system well rather than carrying out a role assignment and performing this processing with two disk drive control units 200,400 performs by one set only of a disk drive control unit. A cheap processor is carried especially as latest commercial-scene trend, and it has become a very important element with high performance and high-reliability to reduce system-wide cost. Therefore, in light penalty processing, although that much accesses to a drive occur also leads to performance degradation, since the transit time of the micro program of the processor which controls it before it is long, a

processor neck has many bird clappers as a system. At this time, the performance near the double precision can be taken out with processing by two sets of the disk drive control units 200 and 400 like this example.
[0041] Next, the reading demand from high order equipment 100 and MPU250 start reading of data from a physical drive (disk unit 500) by the DRVI/F control section 270 and the DRV transfer control section 260, and transmit it to high order equipment 100. Moreover, while the lead demand address from high order equipment 100 is continuing at this time, it may judge that the disk drive control unit 400 is sequential lead processing, and processing which reads asynchronously [I/O from high order equipment 100] an certain amount of data which follows the lead demand address from high order equipment 100 to data buffers 240 and 440 may be performed. When there is next an I/O demand from high order equipment by carrying out like this, the target data are already stored in data buffers 240/440, and data can be transmitted without producing access to the disk unit 500 which time requires, and it leads to the improvement in a performance as the whole.
[0042] As mentioned above, though it is a redundant configuration, it leads not only to reliability but to improvement in a performance by performing a part of processing rather than making a redundant portion (this example disk drive control unit 400) only stand by as an object for the change at the time of obstacle generating.
[0043] Next, in this example, while two sets of the disk drive control units 200/400 perform processing, operation which performs automatic switching and restoration at the time of an obstacle is explained. First, the surveillance procedure which detects an obstacle automatically is explained.
[0044] MPU 250 and 450 sets the information (normal information is called hereafter) which shows that MPU450 of MPU250 is normal to surveillance intelligence 321 whenever fixed time passes controlling the disk drive control units 200 and 400 as surveillance intelligence 322. However, in order to show having set up for every fixed time, the information which changes serially is set to this information. For example, it is the information which is added one [at a time]. Moreover, when accessing a data buffer is that each MPU250,450 judged normally that operation was impossible with the disk drive control unit 200,400 concerned impossible from MPU, for example, the information (this is called obstacle information below) which shows that it is an obstacle is set as surveillance intelligence. Hereafter, the flow chart of drawing 4 explains an example of the above-mentioned surveillance procedure.
[0045] Here, MPU450 of the disk drive control unit 400 takes and explains to an example operation which supervises the disk drive control unit 200 of an other system.
[0046] MPU250 judges first whether fixed time passed at Step 600. If fixed time has not passed, it progresses to Step 608 and it is judged that the disk drive control unit 200 is normal.
[0047] If fixed time has passed, it will progress to Step 601 and the normal information which shows that MPU450 is normal will be set up. And it progresses to Step 602 and the surveillance intelligence 322 of the disk drive control unit 200 is referred to. If it judges whether this information is normal and judges that it is normal at Step 603, it will progress to Step 604. If it judges that it is an obstacle, it will progress to Step 607 and it will be judged that the disk drive control unit 200 is an obstacle.
[0048] At the time of normal information, it progresses to Step 605 and judges at Step 605 whether this normal information had change from before. That is, MPU250 may have fallen impossible [a setup of surveillance intelligence] according to the obstacle of a micro program etc. Such an obstacle is judged with the check of this step 605. If there is change, it will progress to Step 608 and it will be judged that it is normal. When there is no change, it progresses to Step 606 and judges whether the time of a margin longer than fixed time has passed. Consequently, if it has passed, it progresses to Step 607 and is judged as an obstacle, and if it has not passed, it will progress to Step 608 and it will be judged that it is normal. According to the above surveillance procedure, both of obstacles of a micro program can also detect the obstacle of hardware simultaneously.
[0049] Next, an example of the processing from which the disk drive control unit 400 recognizes the obstacle of the disk drive control unit 200 of an other system, and changes with reference to

the flow chart of drawing 5 is explained.
[0050] Refer to the load-distribution information 350 for MPU450 serially at Step 700 first. Consequently, if the light data from high order equipment 100 do not exist in a data buffer 240 and 440 at Step 701, it progresses to Step 704. If it exists, in order to progress to Step 702 and to generate the parity corresponding to the light data of a data buffer 440, the old data and the old parity data corresponding to the light data concerned are read from a disk unit 500, and new parity data are generated in the ECC generation circuit 480. Then, it progresses to Step 703 and light data and new parity data are stored in a disk unit 500 by the DRV transfer control section 460 and the DRVI/F control section 470. Next, at Step 704, the obstacle of the disk drive control unit 200 is checked in the surveillance procedure after Step 600 of drawing 4 . Consequently, if normal, it will progress to Step 700 and processing will be continued. If it judges that a change is required, it will progress to Step 710 and reception of I/O from high order equipment 100 will be changed from the disk drive control unit 200 to the disk drive control unit 400 using change procedure. And the disk drive control unit 400 substitutes Step 720 for the I/O processing from high order equipment 100 which the disk drive control unit 200 was performing, and it is performed.
[0051] Next, it changes with the flow chart of drawing 6 , and an example of procedure is explained.
[0052] At Step 711, it directs to write the data concerned in a data buffer 440 one-fold to the data transfer control section 430 at the time of the light data receipt from high order equipment 100 first. That is, since a data buffer does not exist in the disk drive control unit 400 until it exchanges the part which the disk drive control unit 200 was degenerated, separated, and carried out obstacle generating and restores, since the obstacle occurred in the disk drive control unit 200, double writing like [at the time of a normal redundant configuration] is not made.
[0053] And it directs to change the I/O demand from high order equipment 100 from the host I/F control section 210 to the host I/F control section 410 by the change mechanism 420 by Step 712. Although it stops receiving the demand from high order equipment 100, as for the host I/F control section 210, the host I/F control section 410 will come to receive the demand from high order equipment 100 and a disk drive control unit will change substantially by this, at this example, there is no need of knowing the disk drive control unit by the side of receipt having changed that SCSIID should just publish eye the same hatchet and high order equipment 100 to SCSIID same before changing I/O.
[0054] Next, after changing using the flow chart of drawing 7 , an example of a procedure which performs I/O with the disk drive control unit 400 is explained.
[0055] If I/O processing is received from high order equipment 100 at Step 721, it will progress to Step 722 and a lead demand or a light demand will be judged. At the time of a lead demand, it progresses to Step 729 and object data are read into a data buffer 440 from the disk unit 500 corresponding to the lead demand concerned. It progresses to Step 730, data are transmitted to high order equipment 100 from a data buffer 440, and Step 728 reports an end to high order equipment 100.
[0056] At the time of a light demand, it progresses to Step 723 and light data are stored in a data buffer 440. Furthermore, it progresses to Step 724 and judges whether it is write-through mode at Step 725 with reference to the data transfer mode information 330. Consequently, it progresses to Step 728 at the time of the mode in which an end is reported to high order equipment 100 when stored at the time 440 of light after mode, i.e., a data buffer, it reports an end, and stores it in a disk unit 500 from a data buffer 440 asynchronously after that. It progresses to Step 726 at the time of write-through mode, it creates the parity data to light data, stores light data and new parity data in a disk unit 500 at Step 727, and reports an end at Step 728. Furthermore, after this, Step 703 is performed from Step 700 in the flow chart of drawing 5 , and processing before a change is also performed.
[0057] Thus, according to this example, mutual change operation and continuation of processing are automatically possible without the directions from high order equipment 100 at the disk drive control units 200/400, without carrying out no consciousness to high order equipment 100.

[0058] Next, the disk drive control unit 200 is restored and an example of the method when returning to the original redundant configuration is explained.
[0059] First, the flow chart shown in drawing 8 explains an example of restoration operation by the side of the disk drive control unit 200. It notifies that restoration was completed to the disk drive control unit 400 by Step 810 at transmitter guard 300. Then, the disk drive control unit 200 turns into a redundant disk drive control unit, and before and a position interchange. At Step 811, asynchronous DESUTEJI processing (Steps 700-705 of drawing 5) which the disk drive control unit 400 was performing is performed before.
[0060] Furthermore, an example of operation of the near disk drive control unit 400 which received the notice with the flow chart shown in drawing 9 is explained.
[0061] If the completion of restoration of the disk drive control unit 200 is recognized at transmitter guard 300 by Step 820, it will point to double writing to data buffers 240 and 440 to the data transfer control section 430 at Step 821, and only I/O processing from high order equipment 100 will be performed at Step 821. Thus, receiving the I/O demand from high order equipment 100, restoring in the original redundant composition is possible, and improvement in a performance can also be aimed at by carrying out the load distribution of the processing with two more disk drive control units 200/400.
[0062] Next, it explains, referring to the flow chart of drawing 10 about an example of the extension method of the data buffer under operation of the disk drive control units 200/400. In addition, let the disk drive control unit which has received I/O from high order equipment 100 be the disk drive control unit 200.
[0063] When there is an extension demand of a data buffer, the disk drive control unit concerned judges whether it is an I/O receiving side at Step 911. The content of processing of the disk drive control unit 200 is explained first. Since the disk drive control unit 200 is an I/O receiving side, it progresses to Step 912, the disk drive control unit 400 degenerates first, and it recognizes separating. Then, it directs to make light data into 1-fold writing to a data buffer 240 to the data transfer control section 230. Then, I/O processing from high order equipment 100 is performed at Step 913, and Step 700 of drawing 5 - Step 703 are performed at Step 914. That is, it substitutes for a part to have performed with the disk drive control unit 400. It waits for the completion of restoration of the disk drive control unit 400, repeating Step 913 and Step 914.
[0064] Next, as for the disk drive control unit concerned, the disk drive control unit 400 also judges whether it is an I/O receiving side at Step 911. Since it is not an I/O receiving side as a result, it progresses to Step 915, and the disk drive control unit 400 concerned detaches, and extends a data buffer 440 at Step 916. It notifies having restored at Step 917 to the disk drive control unit 200 through the transmitter style 300 after the completion of extension.
[0065] Since the disk drive control unit 200 needs to extend shortly, the disk drive control unit 400 changes the host I/F control section which carries out I/O reception using the change mechanism 420 at Step 919 to self-** in order to substitute for receipt of I/O. Then, I/O processing from high order equipment 100 is performed at Step 920, Step 700 of drawing 5 - Step 703 are performed at Step 921, and it waits for the completion of restoration of the disk drive control unit 200.
[0066] The disk drive control unit 200 which has recognized restoration through the transmitter style 300 at Step 918 is separated at Step 922, and extends a data buffer 240 at Step 923. The transmitter style 300 notifies restoration to the disk drive control unit 400 at Step 924 after the completion of extension. After a notice, since the disk drive control unit 200 concerned is not a host I/O receiving side, it turns to the side which performs Step 700 of drawing 5 - Step 705 at Step 925.
[0067] The disk drive control unit 400 will direct to write light data to data buffers 240/440 doubly to the data transfer control section 230 at Step 927, if restoration of an other system is recognized at transmitter guard 300 by Step 926. I/O processing from high order equipment 100 is performed at Step 928.
[0068] Thus, though I/O from high order equipment 100 is performed, extension of the data buffers 240/440 of each ** is attained. That is, according to this example, by the former, extension of extension of a data buffer is attained in online to having been unrealizable unless it

was after suspending a system. Especially when the disk drive control unit was built on one board realized in the low cost, the exchange for every board was impossible for extension under eye a required hatchet and operation. In this example, extension of a data buffer is possible, setting to the disk drive control units 200/400 of a redundant configuration, and degenerating / restoring one set at a time.

[0069] Moreover, according to this example, by transposing processing of Step 916 of drawing 10 , and Step 923 to micro program exchange work, exchange of the micro program under operation is possible, and the demand of 24-hour operation is effective in especially the maintenance control work in a remarkable computer system in recent years.

[0070] Moreover, a user can direct whether for the light demand from high order equipment 100 to be written in by the data buffer, and to report an end, or to write even in a disk unit 500 and report an end during the degeneracy at the time of a piece system obstacle. That is, you may perform automatically rewriting of this data transfer mode information 330 by a user's program. That is, if an end is reported when a data buffer becomes 1st page composition, and stored in data FABBA, although it excels in responsibility, a data guarantee becomes impossible when an obstacle occurs in a disk drive control unit at this time. Since light penalty processing occurs in on the other hand storing even in a disk unit 500, although responsibility will deteriorate considerably, a positive response can be reported to high order equipment 100, and it is reliable. In the case of the external storage of this example, according to the demand level of the reliability to the file which a user treats, it can choose optionally whether priority is given to reliability, or priority is given to a speed of response with directions of a user, and it becomes possible to build a flexible file system.

[0071] Furthermore by this invention, two or more disk drive control units can also offer simultaneously the system which can be accessed not only from redundant composition but from two or more high order equipment or two or more buses. This example of a system configuration is shown in drawing 11 and drawing 12 .

[0072] Although drawing 11 is the same composition as drawing 1 of an example explained until now, when I/F with high order equipment 100 is SCSI, with the composition of drawing 1 , the points connected by SCSIID from which a memory control unit 0 (400A) and a memory control unit 1 (200A) differ differ by the composition of drawing 11 to the memory control unit 0 and the memory control unit 1 having been connected by the same SCSIID. In the composition of this drawing 11 , both receive and process an I/O demand from high order equipment 100. Moreover, drawing 12 is the block diagram showing an example of the system configuration to which two or more memory control units 0 (400B) and memory control units 1 (200B) were connected by the multi-pass to the same high order equipment 100. The composition of this drawing 12 of a memory control unit 0 (400B) and a memory control unit 1 (200B) is all also an execute permission about the I/O demand from high order equipment 100. Specification of any perform an I/O demand is realized by rewriting the host I/O receipt information 340 of the common managed table 310. That is, each memory control unit determines first whether the memory control unit concerned receives I/O from high order equipment with reference to the host I/O receipt information 340. Thus, in this invention, it can respond to various users' connection method, and a flexible system can be built.

[0073] As explained above, while two or more disk drive control units 200/400 of a redundant configuration carry out a load distribution, according to this example, the file system which can realize simultaneously not only the improvement in reliability but improvement in a performance can be offered by performing the demand from high order equipment 100. Moreover, performing the I/O demand from high order equipment 100, while all the disk drive control units 200/400 carry out a load distribution, but, it changes automatically, operation is continued, without looking for directions in any way from high order equipment 100 at the time of obstacle generating, and it becomes possible to restore further. It becomes exchangeable [extension of a data buffer, or a micro program] by this, performing the I/O demand from high order equipment 100, and non-stopped maintenance can be realized. Moreover, not only a redundant configuration but all disk drive control units are possible also for making it the composition which receives the demand from high order equipment 100 simultaneously, and can respond to the various file systems

which a user demands flexibly.

[0074]

[Effect of the Invention] According to the external storage of this invention, the effect that reliability and a performance can be raised is acquired by making two or more memory control units of a redundant configuration distribute a load.

[0075] Moreover, the effect that improvement in the reliability by multiplexing of a memory control unit and control action with a still more various memory control unit are realizable is acquired, without making it conscious of the redundant configuration of a memory control unit to a high order equipment side.

[0076] Moreover, the effect that the maintenance control work of the hardware in two or more memory control units of a redundant configuration, software, etc. is executable simple is acquired, without stopping operation.

[0077] Moreover, the effect that the maintenance control work of composition of having carried the memory control unit and the data buffer on the single board can be done during operation is acquired.

[Translation done.]

* NOTICES *

1.This document has been translated by computer. So the translation may not reflect the original precisely.
2.**** shows the word which can not be translated.
3.In the drawings, any words are not translated.

DESCRIPTION OF DRAWINGS

[Brief Description of the Drawings]
[Drawing 1] It is the conceptual diagram showing an example of the computing system containing the external storage which is one example of this invention.
[Drawing 2] It is the block diagram showing an example of the internal configuration of the disk drive control unit which constitutes the external storage which is one example of this invention.
[Drawing 3] It is the conceptual diagram showing an example of the composition of the common managed table used in the external storage which is one example of this invention.
[Drawing 4] It is the flow chart which shows an example of an operation of the external storage which is one example of this invention.
[Drawing 5] It is the flow chart which shows an example of an operation of the external storage which is one example of this invention.
[Drawing 6] It is the flow chart which shows an example of an operation of the external storage which is one example of this invention.
[Drawing 7] It is the flow chart which shows an example of an operation of the external storage which is one example of this invention.
[Drawing 8] It is the flow chart which shows an example of an operation of the external storage which is one example of this invention.
[Drawing 9] It is the flow chart which shows an example of an operation of the external storage which is one example of this invention.
[Drawing 10] It is the flow chart which shows an example of an operation of the external storage which is one example of this invention.
[Drawing 11] It is the conceptual diagram showing the modification of a topology with the high order equipment in the external storage which is one example of this invention.
[Drawing 12] It is the conceptual diagram showing the modification of a topology with the high order equipment in the external storage which is one example of this invention.
[Description of Notations]
100 [-- Host I/F control section,] -- High order equipment, 200 -- A disk drive control unit, 210 220 [-- Data buffer,] -- A change mechanism, 230 -- A data transfer control section, 240 250 -- A microprocessor unit, 260 -- DRV transfer control section, 270 [-- Transmitter style,] -- An DRVI/F control section, 280 -- An ECC generation circuit, 300 310 [-- Surveillance intelligence,] -- A common managed table, 320 -- Surveillance intelligence, 321 322 [-- Host I/O receipt information,] -- Surveillance intelligence, 330 -- Data transfer mode information, 340 350 [-- Host I/F control section,] -- Load-distribution information, 400 -- A disk drive control unit, 410 420 [-- A data buffer, 450 / -- A microprocessor unit, 460 / -- A DRV transfer control section, 470 / -- An DRVI/F control section, 480 / -- An ECC generation circuit, 500 / -- Disk unit.] -- A change mechanism, 430 -- A data transfer control section, 440

[Translation done.]

(19)日本国特許庁（ＪＰ）　(12)公開特許公報（Ａ）　(11)特許出願公開番号

特開平8－335144

(43)公開日　平成８年(1996)12月17日

(51)Int.Cl.[6]	識別記号	庁内整理番号	ＦＩ		技術表示箇所
Ｇ０６Ｆ　3/06	３０４		Ｇ０６Ｆ　3/06	３０４Ｂ	
11/20	３１０		11/20	３１０Ｂ	
12/16	３１０	7623－5B	12/16	３１０Ｑ	
13/14	３１０	7368－5E	13/14	３１０Ｆ	

審査請求　未請求　請求項の数５　ＯＬ　（全 17 頁）

(21)出願番号　特願平7－139781

(22)出願日　平成７年(1995)６月７日

(71)出願人　000005108
株式会社日立製作所
東京都千代田区神田駿河台四丁目６番地

(72)発明者　松本　佳子
神奈川県小田原市国府津2880番地　株式会社日立製作所ストレージシステム事業部内

(72)発明者　村岡　健司
神奈川県小田原市国府津2880番地　株式会社日立製作所ストレージシステム事業部内

(74)代理人　弁理士　筒井　大和

(54)【発明の名称】　外部記憶装置

(57)【要約】

【目的】　冗長構成の複数の記憶制御装置に負荷を分散させて、信頼性および性能を向上させるとともに、無停止保守を実現する。

【構成】　ディスク装置を制御する冗長構成の複数のディスクドライブ制御装置２００および４００を上位装置に対して同一ＳＣＳＩＩＤで接続するとともに、通信機構３００および共通管理テーブル３１０を介在させて相互の稼働状態の監視および負荷分散情報の設定を行い、正常時には、複数のディスクドライブ制御装置２００および４００の同時稼働による負荷分散によって高性能を実現し、障害や保守作業時には、切替機構２２０および４２０によって障害側の切り離しによる縮退および復旧時の切り替え操作を実行して、無停止稼働および無停止保守を実現する。

図２

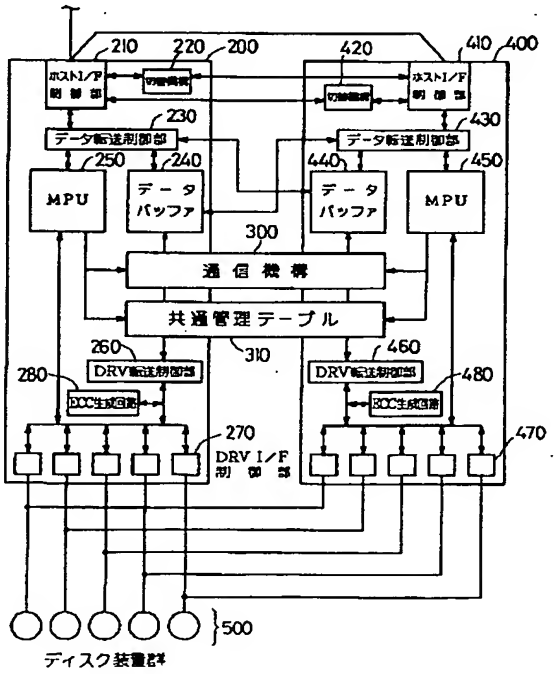

【特許請求の範囲】
【請求項１】　上位装置との間で授受されるデータが格納される記憶装置と、前記記憶装置と前記上位装置との間に介在し、前記上位装置と前記記憶装置との間における前記データの授受を制御する複数の記憶制御装置とを含む外部記憶装置であって、
複数の前記記憶制御装置が前記上位装置からみて等価に見えるように当該記憶制御装置を前記上位装置に接続するインターフェイス手段と、
個々の前記記憶制御装置に設けられ、他の前記記憶制御装置における障害または切替指令の有無を監視する監視手段と、
個々の前記記憶制御装置に設けられ、いずれの前記記憶制御装置が前記上位装置との間における前記データの授受の制御を行うかを切り替える切替手段と、
前記記憶制御装置の相互間における情報の伝達を行う情報伝達手段と、
前記上位装置からの入出力要求に起因する負荷を複数の前記記憶制御装置間にて分担させる負荷分散手段と、を備えたことを特徴とする外部記憶装置。
【請求項２】　請求項１記載の外部記憶装置において、
複数の前記記憶制御装置の各々に設けられ、前記上位装置との間で授受される前記データを一時的に格納するデータバッファと、
前記上位装置からの書き込み要求時、複数の前記データバッファの各々に対して書き込み要求データを選択的または多重に書き込むとともに、前記書き込み要求データの前記データバッファに対する書き込み完了時点で前記上位装置に対して書き込み完了を報告し、前記上位装置からの入出力要求とは非同期に前記データバッファから前記記憶装置へ前記書き込み要求データを反映させるライトアフタ処理、および前記書き込み要求データの前記記憶装置に対する書き込み完了時点で前記上位装置に対して書き込み完了を報告するライトスルー処理を選択的に実行可能なデータ転送制御手段と、を備えたことを特徴とする外部記憶装置。
【請求項３】　請求項１または２記載の外部記憶装置において、
複数の前記記憶制御装置から共通にアクセス可能にされ、個々の前記記憶制御装置が健全か否かを識別するための第１の管理情報、前記ライトアフタ処理および前記ライトスルー処理の何れを実行するかを指定する第２の管理情報、複数の前記記憶制御装置の何れが前記上位装置からの入出力要求を受け付けるかを指定する第３の管理情報、複数の前記記憶制御装置の各々における前記負荷の分担を指定する第４の管理情報の少なくとも一つが格納される管理情報記憶手段と、
障害の発生または外部からの切替指令を契機として、前記障害が発生したか、または外部から指令された前記記憶制御装置を切り離すとともに、残りの前記記憶制御装置によって前記上位装置との間における前記データの授受を継続する縮退運転を行う操作、および切り離されていた前記記憶制御装置を冗長構成に復帰させる操作を行う制御論理と、を備えたことを特徴とする外部記憶装置。
【請求項４】　請求項２記載の外部記憶装置において、
前記データ転送制御手段は、個々の前記記憶制御装置の各々に設けられた前記データバッファの各々に対する前記書き込み要求データの選択的な書き込み操作の停止および再開を行う制御論理を備えたことを特徴とする外部記憶装置。
【請求項５】　請求項４記載の外部記憶装置において、
複数の前記記憶制御装置の中の少なくとも一つを選択的に停止させて縮退運転を行うとともに、停止された前記記憶制御装置に対応するデータバッファの保守または前記記憶制御装置を制御するマイクロプログラムの保守を実行することを特徴とする外部記憶装置。
【発明の詳細な説明】
【０００１】
【産業上の利用分野】本発明は、外部記憶装置に関し、特に、上位装置からの情報の入出力要求を制御する入出力制御装置を多重に備えた冗長構成の外部記憶サブシステム等に適用して有効な技術に関する。
【０００２】
【従来の技術】コンピュータシステムを構成する外部記憶装置においては、記憶媒体を備えた記憶装置と上位装置との間に介在して両者間の情報の授受を制御する記憶制御装置が冗長構成でない場合、記憶制御装置に障害が発生するとサブシステムは停止を余儀なくされ、この間に復旧作業がおこなわれる。そして、この復旧作業が終了すると、記憶制御装置が再起動され、あるいは、サブシステムが再起動されそれまで中断していた業務が再開される。
【０００３】また最近では、コンピュータシステムを用いる様々な情報処理業務において２４時間稼働の運用形態が増加しており、外部記憶サブシステムにも連続運転が要求されている。このため、たとえば、特開平３－２０６５２９号公報に記載されているように、一方の記憶制御装置が運転中、他系の記憶制御装置は停止してスタンバイ状態をとるという、記憶制御装置に関して冗長な構成をとり、記憶制御装置の障害時、他系のスタンバイ状態の記憶制御装置に切り替わることにより、システムを継続運転可能にしようとする技術が知られている。
【０００４】
【発明が解決しようとする課題】しかし、上述の従来技術においては、障害時の連続運転は可能であるが、２台の記憶制御装置を備えているにもかかわらず、実際に稼働するのはいずれか１台のみであり性能的には１台の時となんら変わらなかった。すなわち冗長な他系の記憶制御装置はあくまでホットスタンバイ用であり、障害の記

憶制御装置の単なる代替でしかなかった。

【０００５】また、近年では、システムへの要求も様々であり、上位装置からも複数の経路より、同一の記憶装置へ、または別々の記憶装置へとアクセス要求が発行されるような様々な接続形態があり、従来のような記憶制御装置の単なる冗長構成では、多様なユーザの要請に合わせてシステムを構築することが困難であった。

【０００６】また、従来において、安価なシステムでは１つのボード内に記憶制御装置とデータバッファが搭載された構成となっており、記憶制御装置内のデータバッファの増設等の保守管理を行う場合、データバッファのみの切り放しが不可能なため、システムを一旦停止させた状態でデータバッファを増設し、増設作業の終了後、記憶制御装置やシステムを再起動させ、それまで中断していた業務を再開する、という手順を踏む必要があり、上位装置からの入出力要求（Ｉ／Ｏ）を処理しながら増設等の保守管理作業を遂行することは不可能であった。

【０００７】本発明の目的は、冗長構成の複数の記憶制御装置に負荷を分散させることにより、信頼性および性能を向上させることが可能な外部記憶装置を提供することにある。

【０００８】本発明の他の目的は、上位装置の側に記憶制御装置の冗長構成を意識させることなく、記憶制御装置の多重化による信頼性の向上、さらには記憶制御装置の多様な制御動作を実現することが可能な外部記憶装置を提供することにある。

【０００９】本発明のさらに他の目的は、稼働を停止させることなく、冗長構成の複数の記憶制御装置におけるハードウェアおよびソフトウェア等の保守管理作業を簡便に遂行することが可能な外部記憶装置を提供することにある。

【００１０】本発明のさらに他の目的は、単一のボード上に記憶制御装置およびデータバッファを搭載した構成の保守管理作業を、稼働中に実行することが可能な外部記憶装置を提供することにある。

【００１１】

【課題を解決するための手段】本発明の外部記憶装置は、複数の記憶制御装置が上位装置からみて同一に見えるように記憶制御装置を上位装置に接続するインターフェイス手段と、複数の記憶制御装置間で他の記憶制御装置を監視する監視手段と、記憶制御装置間での情報の伝達が可能な通信手段と、上位装置からの要求を受領している記憶制御装置を切り替える切替手段と、１つの記憶制御装置が受領した上位装置からの入出力要求と、それに付随する処理を複数の記憶制御装置にて負荷分散する負荷分散手段とを含む構成としたものである。

【００１２】また、個々の記憶制御装置に備えられ、記憶制御装置と同様の冗長構成をとることによって上位装置からの書き込みデータを一旦格納するデータバッファと、上位装置からの書き込みデータをデータバッファに格納した時点で上位装置へ終了を報告し、上位装置との要求とは非同期にデータバッファから記憶装置に書き込むとともに、冗長構成の複数のデータバッファのすべてに書き込むか選択的に書き込むかを制御するデータ転送手段とを含む構成としたものである。

【００１３】また、複数の記憶制御装置から共通にアクセス可能にされ、個々の記憶制御装置が健全か否かを識別するための第１の管理情報、ライトアフタ処理およびライトスルー処理の何れを実行するかを指定する第２の管理情報、複数の記憶制御装置の何れが上位装置からの入出力要求を受け付けるかを指定する第３の管理情報、複数の記憶制御装置の各々における負荷の分担を指定する第４の管理情報、の少なくとも一つが格納される管理情報記憶手段を含む構成としたものである。

【００１４】

【作用】本発明の外部記憶装置では、たとえば、一対の第１および第２の記憶制御装置を含む冗長構成であるとき、この第１および第２の記憶制御装置は上位装置と、たとえばＳＣＳＩインターフェースによりデージーチェーン接続され、同一ＳＣＳＩＩＤでアクセスされる。たとえば上位装置からの入出力要求を固定的に第１の記憶制御装置が受領している場合、当該入出力要求の処理に伴う負荷は、複数の記憶制御装置の各々における負荷の分担を指定する第４の管理情報に基づいて他の第２の記憶制御装置に分散され、冗長構成による信頼性の向上と第１および第２の記憶制御装置の並行稼働による入出力処理の処理能力の向上が図れる。

【００１５】また、たとえば上位装置からの入出力要求を固定的に第１の記憶制御装置が受領している場合、第１の記憶制御装置に障害が発生した時、第１の管理情報および監視手段により障害を検出し、切替手段によって要求を受領する記憶制御装置を第２の記憶制御装置に切り替えることにより、上位装置は障害後も同一のＳＣＳＩＩＤに対してＩ／Ｏ要求を発行すればよく、切り替えに対してなんら意識する必要はない。その後、障害となった記憶制御装置を切り放し、縮退運転に入る。部品やマイクロプログラムの交換等の保守作業終了後に第１の記憶制御装置を復旧し、元の冗長構成に復元される。

【００１６】また、各記憶制御装置内にデータバッファを持ち、上位装置からの書き込みデータを第１の記憶制御装置が受領し、ライトアフタ処理を実行している場合、第１の記憶制御装置に障害が発生したことを監視手段により検出し、切替手段により、第１の記憶制御装置から第２の記憶制御装置に入出力要求を受領する記憶制御装置を切り替えた時、同時に、複数のデータバッファに対する多重なデータ書き込み処理から、稼働中の記憶制御装置に備えられたデータバッファに選択的にデータを書き込む処理に切り替える。

【００１７】この時、ライトアフタ処理を実行するかライトスルー処理を実行するかを選択する。この選択は、

管理情報記憶手段の第２の管理情報をユーザが設定することにより可能である。すなわち、ユーザのデータ信頼性に対する要求が高い時は、ライトスルーモードに設定し、信頼性よりは性能を要求する場合は、ライトアフタモードに設定する。

【００１８】第２の記憶制御装置の復旧後、選択的な書き込みか多重書き込みに切り替えることによりデータバッファに多重に書き込む操作に切り替え、冗長構成に復元できる。

【００１９】上位装置からの入出力要求を第１の記憶制御装置が受領し、上位装置からの書き込み要求に関しては、第１の記憶制御装置のデータバッファと第２の記憶制御装置のデータバッファに２重書きを行い、ライトアフタ処理を行なっている場合、多重に書き込む処理から選択的に書き込む処理に切り替えて第２の記憶制御装置を切り放して縮退させ、データバッファの増設やマイクロプログラムの交換等の保守を行なった後、元の冗長構成に復旧させる。その後、記憶制御装置間での情報の伝達が可能な通信手段用いて第２の記憶制御装置は第１の記憶制御装置にデータバッファの増設等の保守作業の完了を通知し、通知後、切替手段を用い、上位装置からの要求の受領を自装置に切り替える。

【００２０】一方、通知を受けた第１の記憶制御装置は自装置を縮退させ、データバッファの増設等の保守を行ない復旧させる。復旧後、情報の伝達が可能な通信手段を用いて第１の記憶制御装置は第２の記憶制御装置にデータバッファの増設等の保守完了を通知する。これを契機に、単一のデータバッファに対する選択的なデータ書き込みから、複数のデータバッファに対する多重書き込み処理に切り替える。これにより、一対の第１の記憶制御装置および第２の記憶制御装置のデータバッファの増設やマイクロプログラムの交換等の保守管理業務を、上位装置との間における入出力処理を継続しながら可能となる。

【００２１】また、本発明によれば、管理情報記憶手段に設定されている複数の前記記憶制御装置の何れが前記上位装置からの入出力要求を受け付けるかを指定する第３の管理情報を参照することにより、第１の記憶制御装置および第２の記憶制御装置は、上位装置からの要求をいずれが受領するかを判断することが可能である。これにより、たとえば、第１の記憶制御装置および第２の記憶制御装置のどちらか一方のみが上位装置からの要求を受け付けることに限らず、両方の記憶制御装置にて入出力要求を受け付けて処理することも可能である。また、第３の管理情報をユーザにて随意に設定することにより、上位装置からの要求を受ける記憶制御装置をユーザから任意に指定することが可能となる。

【００２２】

【実施例】以下、本発明の実施例を図面を参照しながら詳細に説明する。

【００２３】図１は本発明の一実施例である外部記憶装置を含む計算機システムの一例を示す概念図である。本実施例の計算機システムは、中央処理装置である上位装置１００と、ディスクドライブ制御装置２００、ディスクドライブ制御装置４００と、ディスク装置５００とを含んでいる。ディスクドライブ制御装置２００とディスクドライブ制御装置４００は上位装置１００とＳＣＳＩインターフェースのデージーチェーンで接続され、ディスクドライブ制御装置２００、４００は同一のＳＣＳＩＩＤが設定され、冗長構成をとっている。そして本実施例の場合、ディスクドライブ制御装置２００は、上位装置１００からの要求を受領し、要求に付随する処理をディスクドライブ制御装置２００と冗長なディスクドライブ制御装置４００とで実行し、ディスク装置５００を制御する。

【００２４】図２は、ディスクドライブ制御装置２００および４００の内部構成の一例を示すブロック図である。なお、ディスクドライブ制御装置２００とディスクドライブ制御装置４００の内部構成は同一であるため、ディスクドライブ制御装置２００を例に説明し、ディスクドライブ制御装置４００の側については対応する部位の符号の下２桁を同一にして説明は割愛する。

【００２５】マイクロプロセッサユニット２５０（以下ＭＰＵと称す）は、ランダムアクセスメモリ（ＲＡＭ、図示せず）を逐次デコードしながら実行し、ディスクドライブ制御装置２００の全体を制御している。

【００２６】ホストＩ／Ｆ制御部２１０は、上位装置１００とのプロトコル制御を行なっている。ＤＲＶＩ／Ｆ制御部２７０は各ドライブとのプロトコル制御を行なっている。データバッファ２４０は、ホストＩ／Ｆ制御部２１０とＤＲＶＩ／Ｆ制御部２７０のデータ転送時に用いられるものである。このメモリは揮発メモリでもよいし不揮発メモリでもよい。本実施例は揮発メモリでデータバッファ２４０を構築した場合を例に記述する。

【００２７】切替機構２２０は、各ディスクドライブ制御装置２００およびディスクドライブ制御装置４００のホストＩ／Ｆ制御部２１０およびホストＩ／Ｆ制御部４１０に対し、上位装置１００からのＩ／Ｏを受領するホストＩ／Ｆ制御部を切り替えるためのものである。この実施例では、ホストＩ／Ｆ制御部２１０が受領しているものとする。データ転送制御部２３０は上位装置１００とデータバッファ２４０とのデータ転送を制御している。このデータ転送制御部２３０は上位装置１００からのライトデータをデータバッファ２４０とデータバッファ４４０の２面に２重書きするか、データバッファ２４０のみの１重書きするかの両方の機能を備えている。また、ＭＰＵ２５０からの指示により１重書きか２重書きかを切り替えることが可能である。

【００２８】ＤＲＶ転送制御部２６０はデータバッファ２４０とディスク装置５００との間のデータ転送を制御

する。

【００２９】通信機構３００は、ＭＰＵ２５０と、ＭＰＵ４５０間での情報の伝達をするための機構である。この通信機構３００はＭＰＵ２５０とＭＰＵ４５０間における双方向の伝達を可能としている。

【００３０】共通管理テーブル３１０は、ＭＰＵ２５０とＭＰＵ４５０の双方から参照／更新が可能な管理テーブルである。

【００３１】本実施例では、上位装置１００からの論理データを複数のディスク装置５００へ分散させて格納する、アレイ構成によるドライブ格納方式を例に採って説明する。

【００３２】ＥＣＣ生成回路２８０は、上位装置１００より送られてきたデータに対して冗長データを生成する機能を有し、この機能はデータの復元にも用いることができる。冗長データを付加する単位は、上位から送られてきた１論理データ単位でもよいし複数の論理データ単位に対してでもよい。本実施例は、４つの論理データに対し冗長データを付加し、この冗長データを格納するドライブを固定しないＲＡＩＤ５方式において記述する。

【００３３】次に、図３を参照して共通管理テーブル３１０の構成の一例について説明する。監視情報３２０は各ディスクドライブ制御装置２００／４００が正常に動作しているかどうかをチェックするのに用いられる。監視情報Ａ３２１はディスクドライブ制御装置２００のＭＰＵ２５０が正常に動作可能と判断された時、一定間隔にて情報を設定する。また、ＭＰＵ２５０が正常に動作不能と判断した時、異常を示す情報を設定する。なお、ディスクドライブ制御装置４００のＭＰＵ４５０も、ＭＰＵ２５０と同様に情報を監視情報Ｂ３２２に設定する。

【００３４】データ転送モード情報３３０は、システムの縮退状態時に上位装置１００からのライトデータ書き込み要求に対する終了報告契機を指示する。すなわち、この情報がデータバッファ２４０、またはデータバッファ４４０に対する書きこみ完了時点で上位装置１００に終了を報告するか（以下ライトアフタモードと称す）、データバッファ２４０からディスク装置５００にまで書き込んだ時点で終了報告するか（以下ライトスルーモードと称す）を判断するための情報である。

【００３５】ホストＩ／Ｏ受信情報３４０は２つのディスクドライブ制御装置２００／４００の内、Ｉ／Ｏを受信するディスクドライブ制御装置の指示情報が示されている。本実施例では、ディスクドライブ制御装置２００がホストＩ／Ｏ受信側に設定されているものとして説明する。

【００３６】負荷分散情報３５０は、上位装置からのＩ／Ｏに伴う処理を、２つのディスクドライブ制御装置２００／４００間で負荷分散するための情報である。負荷分散の方法は各ディスクドライブ制御装置にアクセス対象とするディスク装置を分割してもよいし、上位装置１００からのＩ／Ｏ要求の処理と、上位装置１００からのＩ／Ｏ要求とは非同期のデータバッファからディスク装置５００へライトデータを格納する処理とに分担してもよい。または処理しなければならない事柄を全て負荷分散情報の中に書き込み、２つのＭＰＵ間で競争論理とし、ＭＰＵとして空きがあるほうが処理を実行するという方法でもかまわない。

【００３７】本実施例では上位装置１００からのＩ／Ｏ要求の処理と、上位装置１００からのＩ／Ｏ要求とは非同期にデータバッファ２４０／４４０からディスク装置５００へライトデータを格納する処理とに分担する方式について説明する。よって、本実施例では、負荷分散情報３５０にはデータバッファ２４０／４４０に格納されたライトデータの情報が入っているものとする。

【００３８】次に本実施例における計算機システムでの、上位装置１００からディスク装置５００に対するデータの書き込み処理および読み込み処理について説明する。

【００３９】ディスクドライブ制御装置２００は、通常、上位装置１００からの書き込み要求時、ホストＩ／Ｆ制御部２１０により、書き込み論理データを受領し、データ転送制御部２３０にてデータバッファ２４０とデータバッファ４４０に２重に格納し、共通管理テーブル３１０の負荷分散情報３５０に格納情報を設定し、この時点で上位装置１００に終了を報告する。ＭＰＵ４５０は、逐次、負荷分散情報３５０を参照し、格納情報があれば、当該ライトデータと同一アドレスの、既にドライブに格納されているデータ（以下旧データと称す）と、当該ライトデータに対応するパリティデータをＤＲＶＩ／Ｆ制御部４７０とＤＲＶ転送制御部４６０によりディスク装置５００から読み出し、ＥＣＣ生成回路４８０にてライトデータと旧データとパリティデータにて、ライトデータに対応したパリティデータ（以下新パリティデータと称す）を生成する。生成された新パリティデータとライトデータをＤＲＶＩ／Ｆ制御部４７０とＤＲＶ転送制御部４６０によりディスク装置５００に書き込むことにより、ライトデータをディスク装置５００に格納する。この処理は上位装置１００からのＩ／Ｏ要求とは非同期に行なわれる。また、ライトデータを格納するために行なわれる、旧データ／旧パリティデータの読み出し処理及び新パリティ生成処理、新パリティデータ格納処理はＲＡＩＤ５におけるライトペナルティと呼ばれている。

【００４０】このように、上位装置１００からのライトデータの格納要求は、複数のディスク装置５００をディスクアレイ装置として機能させる場合において、非常に負荷が高い処理である。この処理を２つのディスクドライブ制御装置２００、４００にて役割分担し実行することは、１台のディスクドライブ制御装置だけで実行する

より、効率がよくシステムとしての性能向上につながる。特に最近の市場動向としては、安価なプロセッサを搭載し、システム全体のコストを低減させることが、高性能、高信頼性とともに、非常に大切な要素となっている。よって、ライトペナルティ処理においては、ドライブへのアクセスが多数発生することも性能劣化につながるが、それ以前にそれを制御するプロセッサのマイクロプログラムの走行時間が長いために、システムとしてプロセッサネックになることも多い。この時、本実施例のように、２台のディスクドライブ制御装置２００および４００にて処理を行なうことで２倍近くの性能を出すことができる。

【００４１】次に上位装置１００からの読み込み要求時、ＭＰＵ２５０は、ＤＲＶＩ／Ｆ制御部２７０とＤＲＶ転送制御部２６０により物理ドライブ（ディスク装置５００）よりデータの読み込みを開始し、上位装置１００に転送する。また、この時、上位装置１００からのリード要求アドレスが連続していた時、ディスクドライブ制御装置４００がシーケンシャルリード処理だと判断し、上位装置１００からのリード要求アドレスに続くあるデータ量を上位装置１００からのＩ／Ｏとは非同期にデータバッファ２４０および４４０に読み出す処理を行っても良い。こうすることにより、次に上位装置からＩ／Ｏ要求があった時、対象となるデータがすでにデータバッファ２４０／４４０に格納されており、時間の掛かるディスク装置５００へのアクセスを生じることなくデータを転送することができ、全体としての性能向上につながる。

【００４２】以上のように、冗長構成でありながら、冗長な部分（本実施例では、ディスクドライブ制御装置４００）を障害発生時の切り替え用として単にスタンバイさせておくのではなく、処理の一部を実行させることにより、信頼性だけでなく性能の向上にもつながる。

【００４３】次に本実施例において、２台のディスクドライブ制御装置２００／４００が処理を実行しながら、障害時の自動切り替えおよび復旧を実行する動作について説明する。まず、自動的に障害を検出する監視手続きについて説明する。

【００４４】ＭＰＵ２５０、４５０はディスクドライブ制御装置２００、４００を制御しながら、一定時間が経過する度に、ＭＰＵ２５０は監視情報３２１に、ＭＰＵ４５０は監視情報３２２に正常であることを示す情報（以下、正常情報と称す）を設定する。但し、一定時間毎に設定していることを示すために、この情報には逐次変化する情報を設定する。たとえば、１つずつ加算されるような情報である。また、各ＭＰＵ２５０，４５０が、当該ディスクドライブ制御装置２００、４００にて正常に動作が不可能と判断したと、たとえば、ＭＰＵからデータバッファがアクセス不可能となった時、監視情報に障害であることを示す情報（以下これを障害情報と称す）を設定する。以下、図４のフローチャートにより前述の監視手続きの一例を説明する。

【００４５】ここでは、ディスクドライブ制御装置４００のＭＰＵ４５０が他系のディスクドライブ制御装置２００の監視を行う動作を例に採り説明する。

【００４６】まずＭＰＵ２５０はステップ６００にて一定時間が経過したかを判断する。一定時間が経過していなければ、ステップ６０８へ進み、ディスクドライブ制御装置２００が正常と判断する。

【００４７】一定時間が経過していれば、ステップ６０１へ進み、ＭＰＵ４５０が正常であることを示す正常情報を設定する。そしてステップ６０２へ進み、ディスクドライブ制御装置２００の監視情報３２２を参照する。この情報が正常か否かを判断し、ステップ６０３にて正常だと判断したら、ステップ６０４に進む。障害であると判断したら、ステップ６０７に進み、ディスクドライブ制御装置２００は障害であると判断する。

【００４８】正常情報の時、ステップ６０５に進み、この正常情報に以前から変更があったかどうかをステップ６０５にて判断する。すなわち、ＭＰＵ２５０がマイクロプログラムの障害等により、監視情報を設定不可能に陥っている可能性がある。このような障害を、このステップ６０５のチェックにて判断する。変更があれば、ステップ６０８へ進み、正常と判断する。変更が無かったとき、ステップ６０６に進み、一定時間よりも長いマージンの時間が経過しているか否かを判断する。その結果、経過していれば、ステップ６０７へ進み、障害と判断し、経過していなければ、ステップ６０８へ進み、正常と判断する。以上のような監視手続きによれば、ハードウェアの障害も、マイクロプログラムの障害も両方同時に検出が可能である。

【００４９】次に、図５のフローチャートを参照してディスクドライブ制御装置４００が他系のディスクドライブ制御装置２００の障害を認識して切り替わる処理の一例を説明する。

【００５０】まずＭＰＵ４５０はステップ７００にて逐次、負荷分散情報３５０を参照している。その結果、ステップ７０１にてデータバッファ２４０、４４０内に上位装置１００からのライトデータが存在しなければ、ステップ７０４に進む。存在すれば、ステップ７０２に進み、データバッファ４４０のライトデータに対応するパリティを生成するため、当該ライトデータに対応する旧データと旧パリティデータをディスク装置５００から読み出し、ＥＣＣ生成回路４８０にて新パリティデータを生成する。その後、ステップ７０３に進み、ライトデータと新パリティデータをＤＲＶ転送制御部４６０および、ＤＲＶＩ／Ｆ制御部４７０によりディスク装置５００に格納する。次にステップ７０４にて、図４のステップ６００以降の監視手続きによりディスクドライブ制御装置２００の障害をチェックする。その結果、正常なら

ば、ステップ７００に進み、処理を続ける。切り替えが必要と判断したら、ステップ７１０に進み、切り替え手続きを用いて、上位装置１００からのＩ／Ｏの受信をディスクドライブ制御装置２００からディスクドライブ制御装置４００に切り替える。そして、ディスクドライブ制御装置２００が行なっていた上位装置１００からのＩ／Ｏ処理をステップ７２０にてディスクドライブ制御装置４００が代替して行なう。

【００５１】次に、図６のフローチャートにて切り替え手続きの一例を説明する。

【００５２】まずステップ７１１にて、データ転送制御部４３０に対し、上位装置１００からのライトデータ受領時、当該データをデータバッファ４４０へ１重に書き込むことを指示する。すなわち、ディスクドライブ制御装置２００に障害が発生したため、ディスクドライブ制御装置２００を縮退させて切り放し、障害発生した部位を交換し、復旧するまでの間、データバッファはディスクドライブ制御装置４００にしか存在しないため、正常な冗長構成時のような２重書きはできない。

【００５３】そして、ステップ７１２にて、切替機構４２０にて上位装置１００からのＩ／Ｏ要求をホストＩ／Ｆ制御部２１０から、ホストＩ／Ｆ制御部４１０に切り替えるよう指示をする。これにより、ホストＩ／Ｆ制御部２１０は上位装置１００からの要求を受け付けなくなり、また、ホストＩ／Ｆ制御部４１０は上位装置１００からの要求を受け付けるようになり、実質的にはディスクドライブ制御装置が切り替わることになるが、本実施例ではＳＣＳＩＩＤが同一なため、上位装置１００はＩ／Ｏを切り替える以前と同様のＳＣＳＩＩＤに発行すればよく、受領側のディスクドライブ制御装置が切り替わったことを知る必要が全くない。

【００５４】次に図７のフローチャートを用いて、切り替わった後、ディスクドライブ制御装置４００にてＩ／Ｏを実行する手順の一例を説明する。

【００５５】ステップ７２１にて上位装置１００よりＩ／Ｏ処理を受信すると、ステップ７２２に進み、リード要求かライト要求かを判断する。リード要求の時、ステップ７２９に進み、当該リード要求に対応するディスク装置５００よりデータバッファ４４０に対象データを読み込む。ステップ７３０に進み、データバッファ４４０から上位装置１００へデータを転送し、ステップ７２８にて上位装置１００に対し、終了を報告する。

【００５６】ライト要求の時、ステップ７２３に進み、データバッファ４４０にライトデータを格納する。さらに、ステップ７２４に進み、データ転送モード情報３３０を参照し、ステップ７２５でライトスルーモードか否かを判定する。その結果、ライトアフタモードの時、すなわちデータバッファ４４０に格納した時点で上位装置１００に対して終了を報告するモードの時は、ステップ７２８に進み、終了を報告し、その後、非同期にデータバッファ４４０からディスク装置５００に格納する。ライトスルーモードの時は、ステップ７２６に進み、ライトデータに対するパリティデータを作成し、ステップ７２７にてライトデータと新パリティデータをディスク装置５００に格納し、ステップ７２８にて終了を報告する。さらに、この後、図５のフローチャートにおけるステップ７００からステップ７０３を実行し、切り替え以前の処理も実行する。

【００５７】このように、本実施例によれば、上位装置１００からの指示なしに、上位装置１００になんの意識もさせずに、ディスクドライブ制御装置２００／４００にて、自動的に相互間の切り替え動作および処理の続行が可能である。

【００５８】次に、ディスクドライブ制御装置２００が復旧し、元の冗長構成に戻る時の方法の一例を説明する。

【００５９】まず、図８に示されるフローチャートにて、ディスクドライブ制御装置２００の側の復旧動作の一例について説明する。ステップ８１０で、通信機構３００にてディスクドライブ制御装置４００に対して復旧が完了したことを通知する。その後、ディスクドライブ制御装置２００が冗長なディスクドライブ制御装置となり、以前と立場が入れ替わる。ステップ８１１にて、以前、ディスクドライブ制御装置４００が行なっていた非同期のデステージ処理（図５のステップ７００～７０５）を行なう。

【００６０】さらに、図９に示されるフローチャートにて、通知を受けた側のディスクドライブ制御装置４００の動作の一例を説明する。

【００６１】ステップ８２０にて通信機構３００にてディスクドライブ制御装置２００の復旧完了を認識すると、ステップ８２１でデータ転送制御部４３０にデータバッファ２４０と４４０への２重書きを指示し、ステップ８２１にて上位装置１００からのＩ／Ｏ処理のみを実行する。このように、上位装置１００からのＩ／Ｏ要求を受けながら、元の冗長な構成に復旧することが可能であり、さらに２つのディスクドライブ制御装置２００／４００で処理を負荷分散することにより、性能の向上も図れる。

【００６２】次に、ディスクドライブ制御装置２００／４００の稼働中におけるデータバッファの増設方法の一例について図１０のフローチャートを参照しながら説明する。なお、上位装置１００からのＩ／Ｏを受信しているディスクドライブ制御装置は、ディスクドライブ制御装置２００とする。

【００６３】データバッファの増設要求があった時、ステップ９１１にて当該ディスクドライブ制御装置はＩ／Ｏ受信側かを判断する。まずディスクドライブ制御装置２００の処理内容について説明する。ディスクドライブ制御装置２００はＩ／Ｏ受信側なので、ステップ９１２

に進み、ディスクドライブ制御装置４００がまず縮退し、切り放すことを認識する。そこで、データ転送制御部２３０にデータバッファ２４０へライトデータを１重書きとするよう指示をする。その後、ステップ９１３にて上位装置１００からのＩ／Ｏ処理を実行し、ステップ９１４にて、図５のステップ７００～ステップ７０３を実行する。すなわちディスクドライブ制御装置４００にて実行していた分を代替する。ステップ９１３とステップ９１４を繰り返しながらディスクドライブ制御装置４００の復旧完了を待つ。

【００６４】次にディスクドライブ制御装置４００もステップ９１１にて当該ディスクドライブ制御装置はＩ／Ｏ受信側かを判断する。その結果Ｉ／Ｏ受信側ではないので、ステップ９１５に進み、当該ディスクドライブ制御装置４００は切り放しを行ない、ステップ９１６にてデータバッファ４４０の増設を行なう。増設完了後、ステップ９１７にて復旧したことを通信機構３００を介してディスクドライブ制御装置２００に通知する。

【００６５】今度はディスクドライブ制御装置２００が増設を行なう必要があるため、ディスクドライブ制御装置４００はＩ／Ｏの受領を代替するため、ステップ９１９で切替機構４２０を用いてＩ／Ｏ受信するホストＩ／Ｆ制御部を自系に切り替える。その後、ステップ９２０にて上位装置１００からのＩ／Ｏ処理を実行し、ステップ９２１にて図５のステップ７００～ステップ７０３を実行し、ディスクドライブ制御装置２００の復旧完了を待つ。

【００６６】ステップ９１８で復旧を通信機構３００を介して認識したディスクドライブ制御装置２００は、ステップ９２２にて切り放し、ステップ９２３にてデータバッファ２４０の増設を行なう。増設完了後、ステップ９２４にて復旧を通信機構３００にてディスクドライブ制御装置４００に通知する。通知後、当該ディスクドライブ制御装置２００はホストＩ／Ｏ受信側ではないのでステップ９２５にて図５のステップ７００～ステップ７０５を実行する側に回る。

【００６７】ディスクドライブ制御装置４００は、ステップ９２６にて他系の復旧を通信機構３００にて認識すると、ステップ９２７にてデータ転送制御部２３０にデータバッファ２４０／４４０へライトデータを２重に書くよう指示をする。ステップ９２８にて上位装置１００からのＩ／Ｏ処理を実行する。

【００６８】このように上位装置１００からのＩ／Ｏを実行しながらも各系のデータバッファ２４０／４４０の増設が可能となる。すなわち本実施例によれば、従来ではデータバッファの増設はシステムを停止してからでないと実現できなかったのに対し、オンライン中に増設が可能となる。特に、低コストにて実現されている１つのボード上にディスクドライブ制御装置が構築されているときは、ボード毎の交換が必要なため、稼働中の増設は不可能であった。本実施例では、冗長構成のディスクドライブ制御装置２００／４００において、１台ずつを縮退／復旧させながら、データバッファの増設が可能である。

【００６９】また、本実施例によれば、図１０のステップ９１６および、ステップ９２３の処理をマイクロプログラム交換作業に置き換えることにより、稼働中のマイクロプログラムの交換が可能であり、２４時間運転の要求が著しい近年のコンピュータシステムにおける保守管理作業に特に有効である。

【００７０】また、片系障害時の縮退中、上位装置１００からのライト要求をデータバッファまでに書き込んで終了を報告するか、ディスク装置５００にまで書き込んで終了を報告するかはユーザが指示可能である。すなわち、このデータ転送モード情報３３０の書き換えは、ユーザのプログラムで自動的に行なってもよい。すなわち、データバッファが１面構成になった時、データファッバに格納した時点で終了を報告すれば、応答性にはすぐれているが、この時点でディスクドライブ制御装置に障害が発生すると、データ保証ができなくなる。一方、ディスク装置５００にまで格納するのでは、ライトペナルティ処理が発生してしまうため、応答性はかなり劣化してしまうが、上位装置１００に対しては、確実な応答が報告でき、信頼性は高い。本実施例の外部記憶装置の場合、ユーザが扱うファイルへの信頼度の要求レベルに応じて、ユーザの指示により、信頼度を優先するか、応答速度を優先するかを随意に選択でき、柔軟なファイルシステムを構築することが可能となる。

【００７１】さらに本発明では、複数のディスクドライブ制御装置は冗長な構成だけではなく、複数の上位装置または、複数のバスより、同時にアクセスが可能なシステムも提供できる。このシステム構成例を図１１および図１２に示す。

【００７２】図１１は、これまでに説明した実施例の図１と同じ構成だが、上位装置１００とのＩ／ＦがＳＣＳＩの時、図１の構成では記憶制御装置０と記憶制御装置１は同じＳＣＳＩＩＤで接続されていたのに対して、図１１の構成では記憶制御装置０（４００Ａ）と記憶制御装置１（２００Ａ）は異なるＳＣＳＩＩＤで接続されている点が異なっている。この図１１の構成の場合、どちらも、上位装置１００からＩ／Ｏ要求を受領して処理する。また、図１２は、複数の記憶制御装置０（４００Ｂ）および記憶制御装置１（２００Ｂ）が、同一の上位装置１００に対してマルチパスにより接続されたシステム構成の一例を示すブロック図である。この図１２の構成でも、記憶制御装置０（４００Ｂ）と記憶制御装置１（２００Ｂ）は、いずれも上位装置１００からのＩ／Ｏ要求を実行可能である。いずれがＩ／Ｏ要求を実行するかの指定は共通管理テーブル３１０の、ホストＩ／Ｏ受信情報３４０を書き換えることにより実現される。すな

わち、各記憶制御装置は、まずホストＩ／Ｏ受信情報３４０を参照し、当該記憶制御装置が上位装置からのＩ／Ｏを受信するか否かを決定する。このように、本発明では様々なユーザの接続方法に対応することができ、柔軟なシステムが構築できる。

【００７３】以上説明したように、本実施例によれば、冗長構成の複数のディスクドライブ制御装置２００／４００が負荷分散しながら上位装置１００からの要求を実行することにより、信頼性の向上だけでなく性能の向上も同時に実現することが可能なファイルシステムを提供できる。また、すべてのディスクドライブ制御装置２００／４００が負荷分散しながら上位装置１００からのＩ／Ｏ要求を実行しながらでも、障害発生時に上位装置１００からなんら指示を仰ぐことなく自動的に切り替わって稼働を継続し、さらに復旧することが可能となる。これにより、上位装置１００からのＩ／Ｏ要求を実行しながらデータバッファの増設やマイクロプログラムの交換が可能となり、無停止保守が実現できる。また、冗長構成だけでなく、すべてのディスクドライブ制御装置が同時に上位装置１００からの要求を受信する構成にすることも可能であり、ユーザの要求する多様なファイルシステムに柔軟に対応することができる。

【００７４】

【発明の効果】本発明の外部記憶装置によれば、冗長構成の複数の記憶制御装置に負荷を分散させることにより、信頼性および性能を向上させることができる、という効果が得られる。

【００７５】また、上位装置の側に記憶制御装置の冗長構成を意識させることなく、記憶制御装置の多重化による信頼性の向上、さらには記憶制御装置の多様な制御動作を実現することができる、という効果が得られる。

【００７６】また、稼働を停止させることなく、冗長構成の複数の記憶制御装置におけるハードウェアおよびソフトウェア等の保守管理作業を簡便に遂行することができる、という効果が得られる。

【００７７】また、単一のボード上に記憶制御装置およびデータバッファを搭載した構成の保守管理作業を、稼働中に実行することができる、という効果が得られる。

【図面の簡単な説明】

【図１】本発明の一実施例である外部記憶装置を含む計算機システムの一例を示す概念図である。

【図２】本発明の一実施例である外部記憶装置を構成するディスクドライブ制御装置の内部構成の一例を示すブロック図である。

【図３】本発明の一実施例である外部記憶装置において用いられる共通管理テーブルの構成の一例を示す概念図である。

【図４】本発明の一実施例である外部記憶装置の作用の一例を示すフローチャートである。

【図５】本発明の一実施例である外部記憶装置の作用の一例を示すフローチャートである。

【図６】本発明の一実施例である外部記憶装置の作用の一例を示すフローチャートである。

【図７】本発明の一実施例である外部記憶装置の作用の一例を示すフローチャートである。

【図８】本発明の一実施例である外部記憶装置の作用の一例を示すフローチャートである。

【図９】本発明の一実施例である外部記憶装置の作用の一例を示すフローチャートである。

【図１０】本発明の一実施例である外部記憶装置の作用の一例を示すフローチャートである。

【図１１】本発明の一実施例である外部記憶装置における上位装置との接続形態の変形例を示す概念図である。

【図１２】本発明の一実施例である外部記憶装置における上位装置との接続形態の変形例を示す概念図である。

【符号の説明】

１００…上位装置、２００…ディスクドライブ制御装置、２１０…ホストＩ／Ｆ制御部、２２０…切替機構、２３０…データ転送制御部、２４０…データバッファ、２５０…マイクロプロセッサユニット、２６０…ＤＲＶ転送制御部、２７０…ＤＲＶＩ／Ｆ制御部、２８０…ＥＣＣ生成回路、３００…通信機構、３１０…共通管理テーブル、３２０…監視情報、３２１…監視情報、３２２…監視情報、３３０…データ転送モード情報、３４０…ホストＩ／Ｏ受信情報、３５０…負荷分散情報、４００…ディスクドライブ制御装置、４１０…ホストＩ／Ｆ制御部、４２０…切替機構、４３０…データ転送制御部、４４０…データバッファ、４５０…マイクロプロセッサユニット、４６０…ＤＲＶ転送制御部、４７０…ＤＲＶＩ／Ｆ制御部、４８０…ＥＣＣ生成回路、５００…ディスク装置。

【図１】

図１

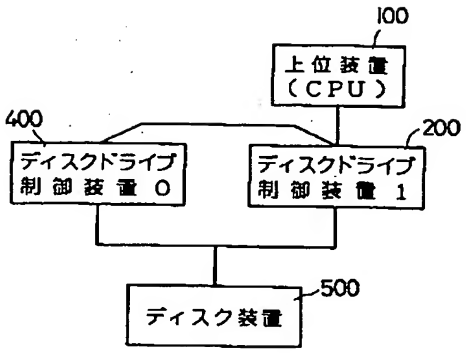

【図３】

図３

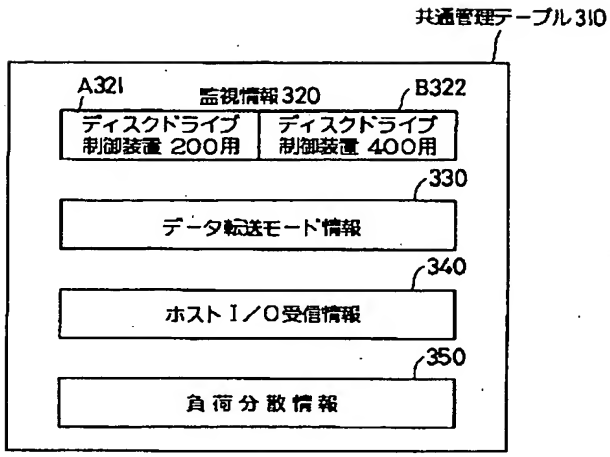

【図６】

図６

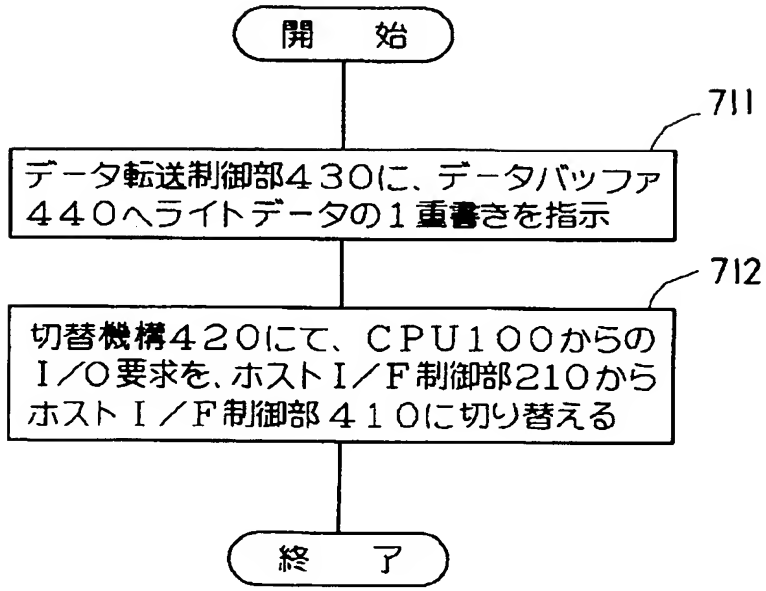

【図２】

図２

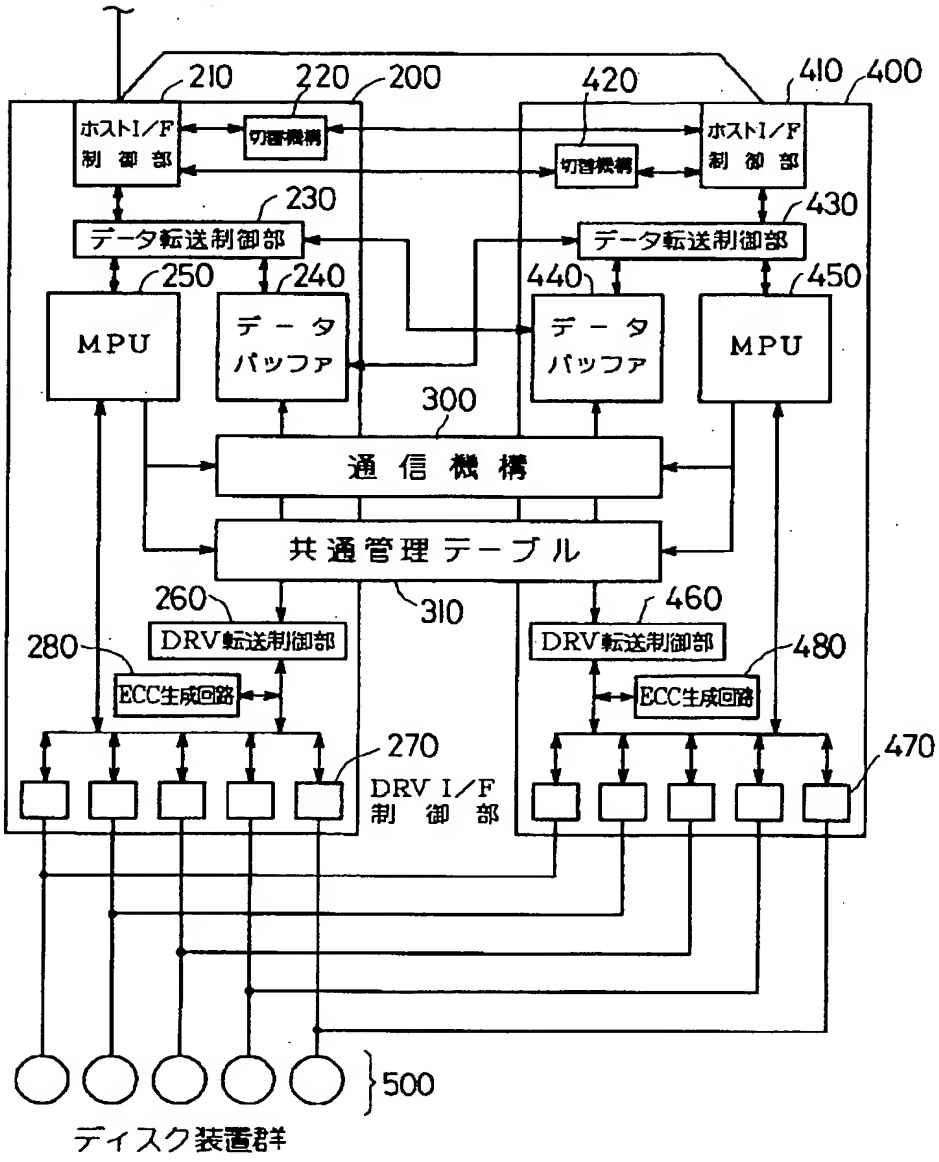
210
220
200
420
410
400
ホストI/F制御部
切替機構
切替機構
ホストI/F制御部
230
430
データ転送制御部
データ転送制御部
250
240
440
450
MPU
データバッファ
データバッファ
MPU
300
通信機構
共通管理テーブル
260
310
460
DRV転送制御部
DRV転送制御部
280
480
ECC生成回路
ECC生成回路
270
470
DRV I/F制御部
500
ディスク装置群

【図４】

図４

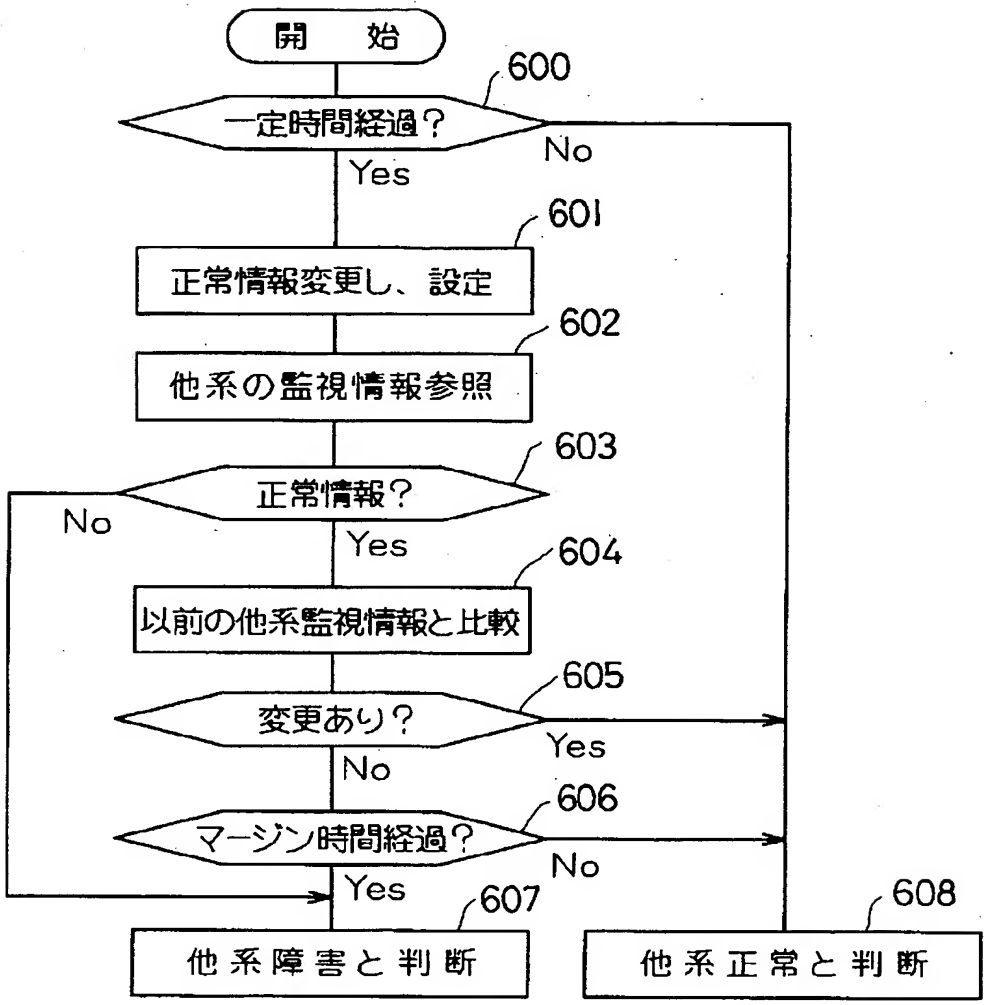
開　始
600
一定時間経過？
No
Yes
601
正常情報変更し、設定
602
他系の監視情報参照
603
正常情報？
No
Yes
604
以前の他系監視情報と比較
605
変更あり？
Yes
No
606
マージン時間経過？
No
Yes
607
他系障害と判断
608
他系正常と判断

【図５】

図５

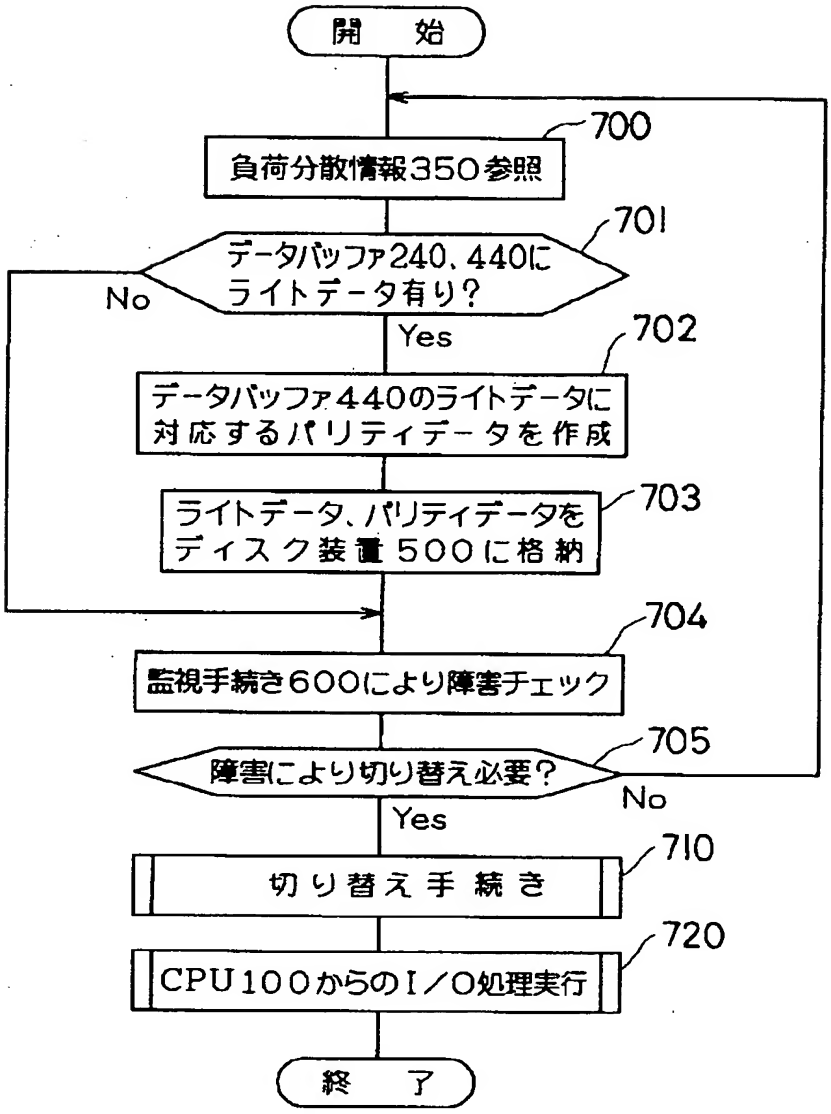
開　始
700
負荷分散情報350参照
701
データバッファ240、440にライトデータ有り？
No
Yes
702
データバッファ440のライトデータに対応するパリティデータを作成
703
ライトデータ、パリティデータをディスク装置500に格納
704
監視手続き600により障害チェック
705
障害により切り替え必要？
No
Yes
710
切り替え手続き
720
CPU100からのI／O処理実行
終　了

【図７】

図７

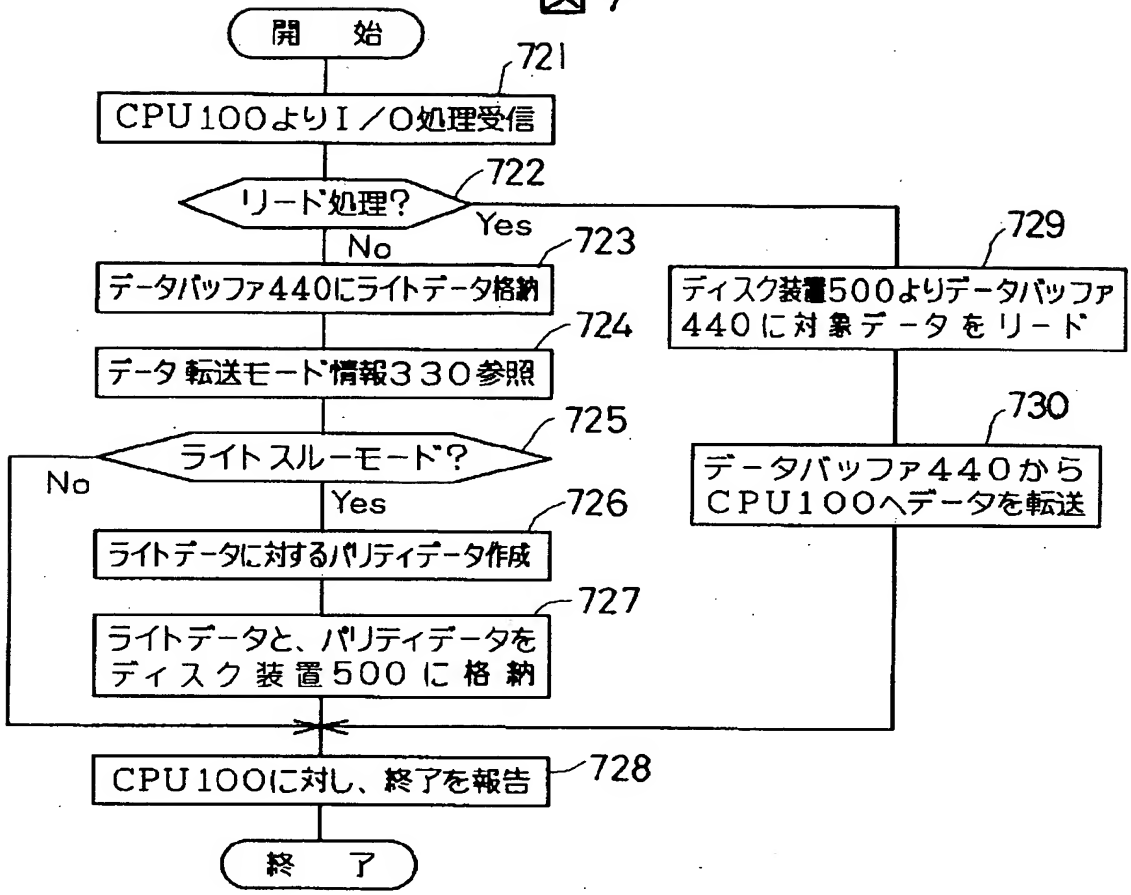
開　始
721
CPU100よりＩ／Ｏ処理受信
722
リード処理?
Yes
No
723
データバッファ440にライトデータ格納
724
データ転送モード情報330参照
725
ライトスルーモード?
No
Yes
726
ライトデータに対するパリティデータ作成
727
ライトデータと、パリティデータを
ディスク装置500に格納
729
ディスク装置500よりデータバッファ
440に対象データをリード
730
データバッファ440から
CPU100へデータを転送
CPU100に対し、終了を報告
728
終　了

【図８】

図８

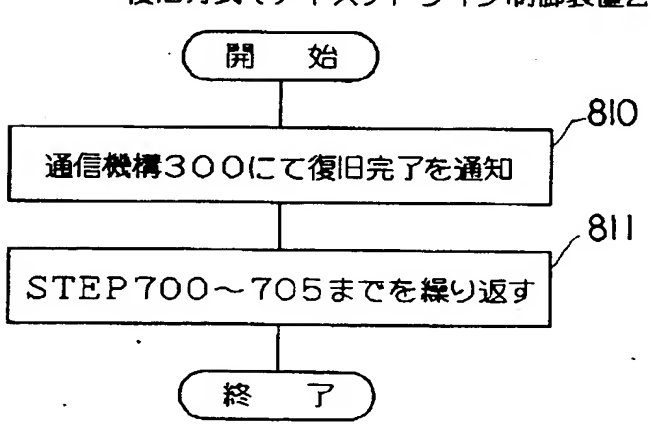
復旧方式（ディスクドライブ制御装置200）
開　始
810
通信機構300にて復旧完了を通知
811
STEP700～705までを繰り返す
終　了

【図９】

図９

復旧方式（ディスクドライブ制御装置４００）

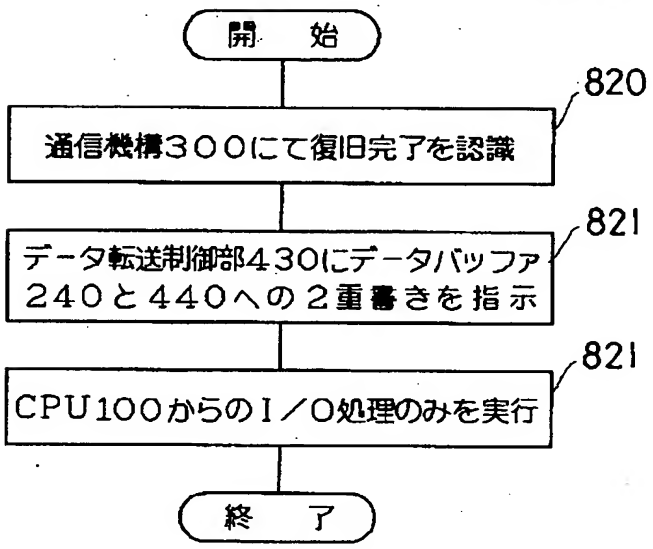

【図１１】

図11

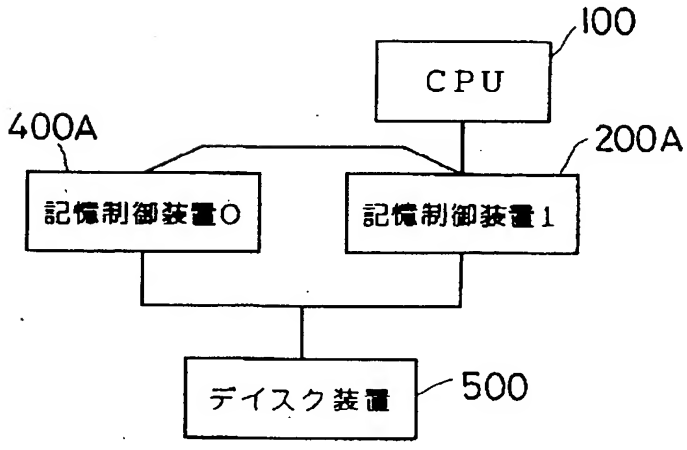

【図１０】

図10

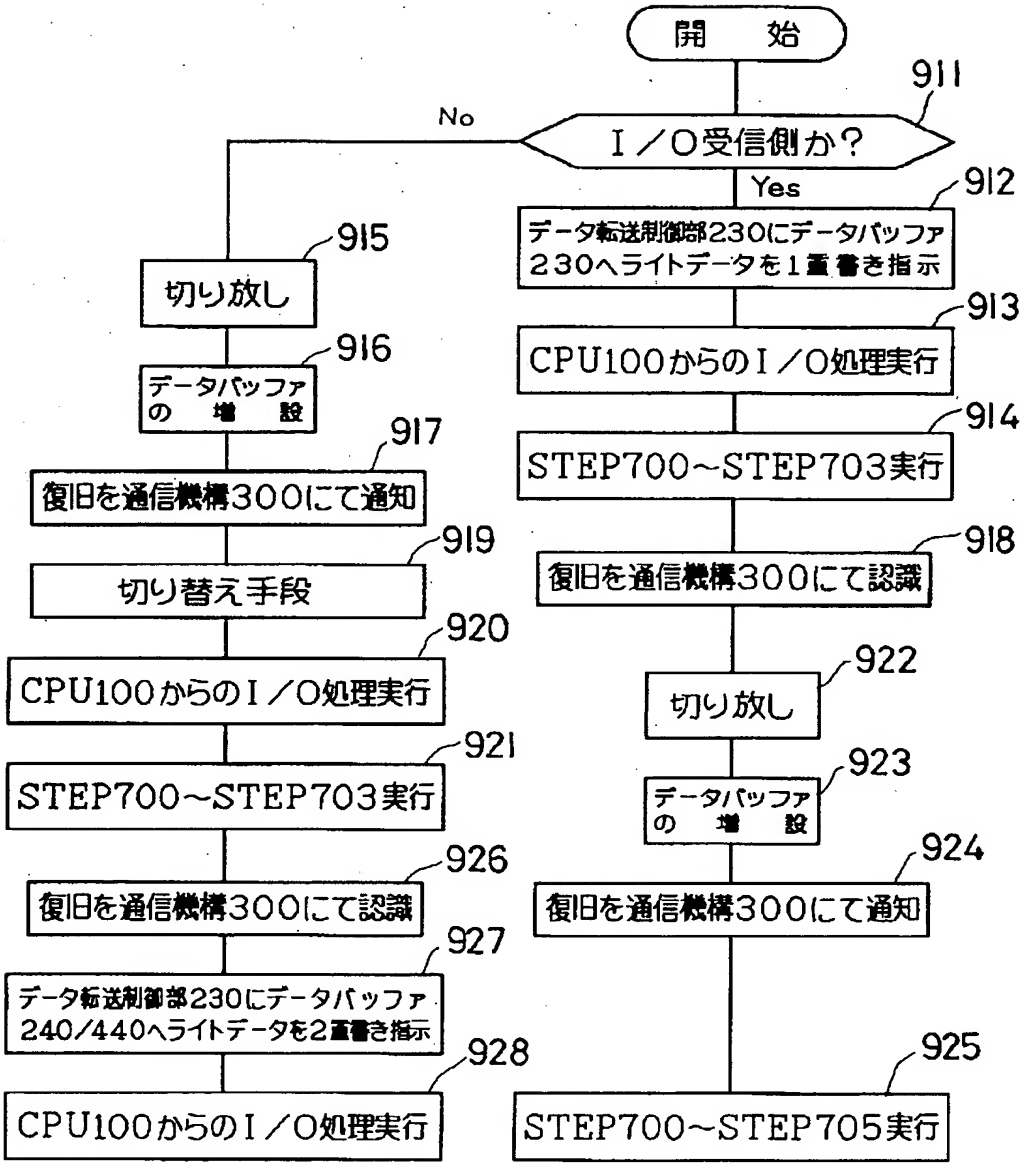
開　始
911
No
I／O受信側か？
Yes
912
データ転送制御部230にデータバッファ230へライトデータを1重書き指示
913
CPU100からのI／O処理実行
914
STEP700～STEP703実行
918
復旧を通信機構300にて認識
922
切り放し
923
データバッファの増設
924
復旧を通信機構300にて通知
925
STEP700～STEP705実行
915
切り放し
916
データバッファの増設
917
復旧を通信機構300にて通知
919
切り替え手段
920
CPU100からのI／O処理実行
921
STEP700～STEP703実行
926
復旧を通信機構300にて認識
927
データ転送制御部230にデータバッファ240/440へライトデータを2重書き指示
928
CPU100からのI／O処理実行

【図１２】

図 12

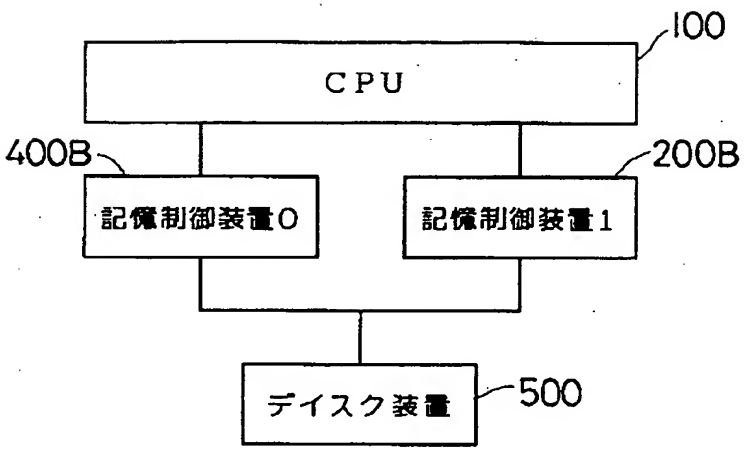

【公報種別】特許法第１７条の２の規定による補正の掲載
【部門区分】第６部門第３区分
【発行日】平成１４年８月３０日（２００２．８．３０）

【公開番号】特開平８－３３５１４４
【公開日】平成８年１２月１７日（１９９６．１２．１７）
【年通号数】公開特許公報８－３３５２
【出願番号】特願平７－１３９７８１
【国際特許分類第７版】
G06F　3/06　304
　　11/20　310
　　12/16　310
　　13/14　310
【ＦＩ】
G06F　3/06　304 B
　　11/20　310 B
　　12/16　310 Q
　　13/14　310 F

【手続補正書】
【提出日】平成１４年６月６日（２００２．６．６）
【手続補正１】
【補正対象書類名】明細書
【補正対象項目名】特許請求の範囲
【補正方法】変更
【補正内容】
【特許請求の範囲】
【請求項１】　上位装置との間で授受されるデータが格納される記憶装置と、前記記憶装置と前記上位装置との間に介在し、前記上位装置と前記記憶装置との間における前記データの授受を制御する複数の記憶制御装置とを含む外部記憶装置であって、
複数の前記記憶制御装置が前記上位装置からみて等価に見えるように当該記憶制御装置を前記上位装置に接続するインターフェイス手段と、
個々の前記記憶制御装置に設けられ、他の前記記憶制御装置における障害または切替指令の有無を監視する監視手段と、
個々の前記記憶制御装置に設けられ、いずれの前記記憶制御装置が前記上位装置との間における前記データの授受の制御を行うかを切り替える切替手段と、
前記記憶制御装置の相互間における情報の伝達を行う情報伝達手段と、
前記上位装置からの入出力要求に起因する負荷を複数の前記記憶制御装置間にて分担させる負荷分散手段と、
を備えたことを特徴とする外部記憶装置。
【請求項２】　請求項１記載の外部記憶装置において、
複数の前記記憶制御装置の各々に設けられ、前記上位装置との間で授受される前記データを一時的に格納するデータバッファと、
前記上位装置からの書き込み要求時、複数の前記データバッファの各々に対して書き込み要求データを選択的または多重に書き込むとともに、前記書き込み要求データの前記データバッファに対する書き込み完了時点で前記上位装置に対して書き込み完了を報告し、前記上位装置からの入出力要求とは非同期に前記データバッファから前記記憶装置へ前記書き込み要求データを反映させるライトアフタ処理、および前記書き込み要求データの前記記憶装置に対する書き込み完了時点で前記上位装置に対して書き込み完了を報告するライトスルー処理を選択的に実行可能なデータ転送制御手段と、
を備えたことを特徴とする外部記憶装置。
【請求項３】　請求項１または２記載の外部記憶装置において、
複数の前記記憶制御装置から共通にアクセス可能にされ、個々の前記記憶制御装置が健全か否かを識別するための第１の管理情報、前記ライトアフタ処理および前記ライトスルー処理の何れを実行するかを指定する第２の管理情報、複数の前記記憶制御装置の何れが前記上位装置からの入出力要求を受け付けるかを指定する第３の管理情報、複数の前記記憶制御装置の各々における前記負荷の分担を指定する第４の管理情報の少なくとも一つが格納される管理情報記憶手段と、
障害の発生または外部からの切替指令を契機として、前記障害が発生したか、または外部から指令された前記記憶制御装置を切り離すとともに、残りの前記記憶制御装置によって前記上位装置との間における前記データの授受を継続する縮退運転を行う操作、および切り離されていた前記記憶制御装置を冗長構成に復帰させる操作を行う制御論理と、

を備えたことを特徴とする外部記憶装置。

【請求項４】　請求項２記載の外部記憶装置において、前記データ転送制御手段は、個々の前記記憶制御装置の各々に設けられた前記データバッファの各々に対する前記書き込み要求データの選択的な書き込み操作の停止および再開を行う制御論理を備えたことを特徴とする外部記憶装置。

【請求項５】　請求項４記載の外部記憶装置において、複数の前記記憶制御装置の中の少なくとも一つを選択的に停止させて縮退運転を行うとともに、停止された前記記憶制御装置に対応するデータバッファの保守または前記記憶制御装置を制御するマイクロプログラムの保守を実行することを特徴とする外部記憶装置。

【請求項６】　上位装置との間で授受されるデータが格納される記憶装置と、

前記記憶装置と前記上位装置との間に介在し、前記上位装置と前記記憶装置との間における前記データの授受を制御する第１の記憶制御装置と、

前記記憶装置と前記上位装置との間に介在し、前記上位装置と前記記憶装置との間における前記データの授受を制御する第２の記憶制御装置と、

前記記憶制御装置から共通にアクセス可能にされ、個々の前記記憶制御装置の管理情報を格納する管理情報記憶手段とを含む外部記憶装置であって、

通常は、前記第１の記憶制御装置が、前記上位装置と前記記憶装置との間で処理されるべき情報であって入出力要求を含むものを処理し、かつ、

前記上位装置と前記記憶装置との間で処理されるべき入出力要求に含まれる情報であって、前記記憶制御装置の各々における負荷の分担を指定する管理情報を、前記管理情報記憶手段に記憶することを特徴とする外部記憶装置。